



Universidad Tecnológica de Pereira

PROGRAMA DE INGENIERÍA FÍSICA

TRABAJO DE GRADO:
EVALUACIÓN DEL MOVIMIENTO EN PACIENTES CON
PARKINSON UTILIZANDO TÉCNICAS COMPUTACIONALES
PARA LA AUTOMATIZACIÓN DEL PROTOCOLO UPDRS
MEDIANTE EL KINECT

AUTOR:
ANDRES DAVID GIL MIRANDA

PEREIRA-2019

EVALUACIÓN DEL MOVIMIENTO EN PACIENTES CON
PARKINSON UTILIZANDO TÉCNICAS COMPUTACIONALES
PARA LA AUTOMATIZACIÓN DEL PROTOCOLO UPDRS
MEDIANTE EL KINECT

ANDRES DAVID GIL MIRANDA

Proyecto de grado presentado como requisito para optar por el título de
ingeniero físico

Director: Walter Serna Serna

UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE INGENIERÍAS ELECTRICA, ELECTRÓNICA,
FÍSICA Y CIENCIAS DE LA COMPUTACIÓN
PEREIRA
2019

Año 2019

NOTA DE ACEPTACIÓN

Jurado

Jurado

Pereira Risaralda, enero 2019

DEDICATORIA

Dedicado a mi madre por su amor constate, a mi padre por su apoyo incondicional en esta etapa de mi vida, a mi hermano por sus consejos, y al resto de mi familia que de una u otra forma contribuyó para alcanzar este logro.

Andrés David Gil Miranda.

AGRADECIMIENTOS

A nuestro padre celestial en primera instancia, ya que le encomendé este camino en sus manos y de él recibí las mayores bendiciones en este andar.

A mi padre, madre y hermano por sus consejos, apoyo y motivación, pues gracias a ellos hoy soy lo que soy.

Al director de este trabajo Walter Serna Serna por la dedicación e interés en este proyecto, por sus valiosos conocimientos los cuales fueron fundamentales para la construcción de este trabajo.

Al grupo de investigación ingeniería biomédica y ciencias forenses BIOIF, como a los demás ingenieros y docentes que participaron en esta etapa de formación.

A mi novia por su apoyo incondicional, motivación y paciencia en estos años.

A mis amigos que de una u otra forma me brindaron un consejo.

Andrés David Gil Miranda.

Resumen

La enfermedad de Párkinson EP, es una patología de carácter neurodegenerativo, la cual afecta los aspectos motores y cognitivos en una persona. La ausencia de dopamina en las neuronas que se localizan en la sustancia negra a nivel cerebral genera alteraciones en el monitoreo de los aspectos motores del cuerpo. Esta enfermedad presenta una sintomatología como temblor en reposo, bradicinesia, rigidez y alteraciones en la marcha. A su vez, la EP desarrolla un cuadro de evolución temporal. Por esta razón es importante la puesta en ejecución de tratamientos clínicos para supervisar el estado de la enfermedad y observar su evolución. Actualmente existe un protocolo que evalúa características cognitivas y ejercicios físicos en pacientes con EP, denominado la Escala unificada de clasificación de la enfermedad de Parkinson UPDRS, desarrolladas por un especialista en neurología. Sin embargo, es una prueba subjetiva a la hora de dar un diagnóstico. En la literatura se encuentran propuestas para obtener una estimación de características de forma cuantitativa, pese a esto se tiene la necesidad de reconocer ciertos ejercicios que son específicos de la EP y que no se han automatizados en el protocolo de aspectos motores del UPDRS. Por esta razón se propone realizar la captura por computador de características cuantitativas en articulaciones, analizando los movimientos especificados en el protocolo UPDRS. Para esto, fueron adquiridas las coordenadas espaciales mediante Microsoft Kinect, ya que es un dispositivo no invasivo, el cual se puede acoplar a un entorno de programación en donde se pretende extraer información característica mediante el algoritmo de clasificación K-nearest neighbors además de algoritmos de reducción de dimensión PCA y Kernel-PCA para realizar un nuevo y mejor muestreo en el espacio de trabajo para las muestras analizadas. En síntesis, se construyó un sistema automático capaz de aprender una serie de posturas corporales que hacen parte de un ejercicio físico propuesto por un estándar y el cual es ejecutado por un sujeto de estudio.

Abstract

Parkinson's disease EP is a pathology of neurodegenerative character, this disease affects the motor and cognitive aspects in a person. The absence of dopamine in the neurons that are located in the nigra substantiate a brain level produce alteration in the monitoring of the motor aspects of the body. This disease presents a symptomatology such as tremor at rest, bradykinesia, rigidity and changes in gait. In turn, PE develops a temporal evolution. For this reason, the execution of clinical treatments is important to monitor the state of the disease and observe its evolution. Currently there is a protocol that evaluates the cognitive characteristics and physical exercises in patients with EP, which is the Unified Scale of Parkinson's disease classification UPDRS, developed by a specialist in neurology. However, it is a subjective test at the time of giving a diagnosis. In the literature we find the proposals to obtain a relation of characteristics of quantitative form. Despite this, there is a need to recognize certain exercises that are specific to EP and that have not been automated like a motor aspects protocol in the UPDRS. For this reason, we has been made the capture of the quantitative characteristics in the joints besides we analyzes the joint movements of the UPDRS protocol, We have acquired the spatial coordinates using Microsoft Kinect, because this is a non-invasive method, which can be coupled in a programming environment, where the characteristic information will be extracted by the nearest K-neighbor classification algorithm, besides to PCA and Kernel-PCA dimension reduction algorithms to perform a new and better sampling in the workspace for the samples analyzed. In short, we built an automatic system capable of learning a series of body postures that are part of a physical exercise improved by a standard and which is executed by a subject of study. In the future, this system will allow a more precise monitoring of the evolution of the Parkinson disease in patients, as well as the possibility of building databases and making comparisons among patients in order to achieve a better understanding of the diseases that affect movement.

Tabla de contenido

Tabla de contenido	I
Índice de Figuras	III
Índice de Tablas	V
Glosario	VI
Nomenclatura	VII
1 Introducción	1
1.1 Descripción del problema.....	1
1.2 Justificación en términos de necesidades y pertinencias.....	1
1.3 Objetivos	2
1.3.1 Objetivo general.....	2
1.3.2 Objetivo específico.....	2
1.4 Marco de antecedentes	2
2 Marco teórico	5
2.1 Enfermedad de Parkinson.....	5
2.1.1 Referencia histórica.....	6
2.1.2 Epidemiología	7
2.1.3 Fisiopatología.....	7
2.1.4 Diagnóstico	9
2.1.5 UPDRS	13
2.2 Estándares y recomendaciones biomecánicas	15
2.2.1 Definición de un sistema de referencia global	15
2.2.2 Definición de sistema de referencia local para centro de masa en segmentos ...	15
2.2.3 Modelo mecánico en articulaciones	16
2.3 Microsoft Kinect.....	17
2.3.1 Arquitectura de Microsoft Kinect.....	18
2.3.2 Sensores internos.....	19
2.3.3 Características de video y audio	20
2.3.4 Ángulo de visión	21
2.3.5 Captura de movimiento	21
2.4 Aprendizaje de máquina	23
2.4.1 Algoritmo de validación K-fold y matriz de confusión.....	23
2.4.2 Análisis de componentes principales PCA y kernel gausiano	26

2.4.3	Algoritmo de clasificación K-nearest neighbors	29
3	Desarrollo experimental.....	30
3.1	Caracterización del aspecto motor en el estándar UPDRS	30
3.1.1	Ficha técnica del sujeto de prueba.....	30
3.1.2	Caracterización del movimiento en la marcha	30
3.1.3	Caracterización del movimiento sentado y de pie.....	31
3.1.4	Caracterización del movimiento en la alternación de las manos	32
3.1.5	Caracterización del movimiento de agilidad en los pies	32
3.2	Propiedades de conexión entre el dispositivo Microsoft Kinect y el entorno de programación Matlab	33
3.2.1	Imagen a color y en profundidad	33
3.2.2	Configuración manual del dispositivo Microsoft Kinect	33
3.2.3	Establecer el modo “TrackingMode” y “BodyPosture”	34
3.3	Adquisición de datos mediante el dispositivo Microsoft Kinect	24
3.3.1	Acceso a datos esqueléticos	34
3.3.2	Visualización del esqueleto en la imagen de formato RGB	34
3.3.3	Obtención de coordenadas espaciales y corrección respecto a la gravedad	35
3.4	Extracción de características a partir de las coordenadas corregidas.....	35
3.4.1	Ejes de orientación para cada articulación	35
3.4.2	Ángulo entre segmentos	38
3.4.3	Distancia de las articulaciones respecto al centro de cadera	38
3.4.4	Definición del centro de gravedad y distancia con respecto a este	39
3.4.5	Velocidad angular para cada articulación.....	39
3.4.6	Definición de variables y metodología de adquisición de datos	40
3.5	Implementación de algoritmos de validación, de reducción de dimensión y clasificación para las muestras adquiridas	41
3.5.1	Matriz de confusión para el algoritmo de clasificación Knn.....	41
3.5.2	Matriz de confusión para el algoritmo de reducción PCA y clasificación Knn ..	41
3.5.3	Matriz de confusión para el algoritmo de reducción PCA con un Kernel gaussiano	41
3.6	Esquema por bloques de la ejecución del desarrollo experimental.....	41
4	Resultados y discusión	43
5	Conclusiones.....	60
6	Trabajos futuros	61
7	Bibliografía.....	62
8	Anexos	67

Índice de Figuras

Figura 1. Metodología propuesta de la captura de la antropometría, Universidad estatal de Pensilvania	3
Figura 2. Reconocimiento de movimiento por fase ejecutada	3
Figura 3. Evolución temporal del centro de masa y piernas en la marcha a nivel tridimensional.....	4
Figura 4. Clasificación de velocidad de marcha por algoritmos de redes neuronales	4
Figura 5. Sistema dopaminérgico.....	5
Figura 6. Molécula de dopamina.....	6
Figura 7. Esquema funcional normal de los ganglios basales	8
Figura 8. Esquema funcional parkinsonismo de los ganglios basales	9
Figura 9. Registro de temblor en un paciente con EP	10
Figura 10. Postura en flexión de un paciente con EP.....	10
Figura 11. Mano estriada y pie deforme de un paciente con EP	10
Figura 12. Marco de referencia global y segmentario a partir de los centros de masa	15
Figura 13. Orientación a partir del marco de referencia para cada centro de masa	16
Figura 14. Definición de sistema de coordenadas en el tórax.....	16
Figura 15. Modelo mecánico de extremidad superior.....	17
Figura 16. Dispositivo Microsoft Kinect	17
Figura 17. Diagrama de Hardware de Microsoft Kinect	18
Figura 18. Proyector infrarrojo, cámara infrarroja, cámara RGB de Microsoft Kinect.....	19
Figura 19. P Funcionamiento del sensor monocromático CMOS	20
Figura 20. Modo Default y Near, rango de distancia admitido por Microsoft Kinect.....	20
Figura 21. Ángulo de visión vertical y horizontal del dispositivo Microsoft Kinect.....	21
Figura 22. Segmentación y obtención de articulaciones a partir de imagen profundidad ...	22
Figura 23. Representación de articulaciones en Microsoft Kinect	23
Figura 24. Representación método de validación Holdout	24
Figura 25. Representación método de validación K-Fold.....	24
Figura 26. Análisis de componentes principales	26
Figura 27. Clasificador K vecinos mas cercanos Knn	29
Figura 28. Ciclo de la marcha y fases de movimiento	31
Figura 29. Caracterización de movimiento levantarse de un asiento	31
Figura 30. Caracterización de movimiento alternado de las manos	32
Figura 31. Caracterización de movimiento de agilidad en los pies	32
Figura 32. a. Imagen RGB, b. Imagen profundidad Microsoft Kinect	33
Figura 33. Esqueleto en imagen RGB mediante Microsoft Kinect.....	35
Figura 34. Definición de los ejes orientados para una articulación	36
Figura 35. Articulaciones a manipular	37
Figura 36. Ángulos entre ejes de orientación.....	38
Figura 37. Distancia de cada articulación a centro de cadera	39
Figura 38. Distancia de cada articulación a centro de gravedad	39
Figura 39. Protocolo de adquisición	40
Figura 40. Etapas del desarrollo experimental	42
Figura 41. Tasa de reconocimiento para las muestras adquiridas en la marcha	44

Figura 42. Agrupación de muestras referente al ejercicio marcha con PCA	44
Figura 43. Agrupación de muestras referente al ejercicio marcha con KPCA.	46
Figura 44. Tasa de reconocimiento ejercicio sentado de pie.	46
Figura 45. Agrupación de muestras referente al ejercicio sentado de pie con PCA.	47
Figura 46. Agrupación de muestras referente al ejercicio sentado de pie con KPCA.	48
Figura 47. Tasa de reconocimiento ejercicio alternación manos.	48
Figura 48. Agrupación de muestras referente al ejercicio alternación manos con PCA.....	48
Figura 49. Agrupación de muestras referente al ejercicio alternación manos con KPCA...	49
Figura 50. Tasa de reconocimiento ejercicio agilidad pie derecho	50
Figura 51. Agrupación de muestras referente al ejercicio agilidad pie derecho con PCA...	50
Figura 52. Agrupación de muestras referente al ejercicio agilidad pie derecho con KPCA	51
Figura 53. Tasa de reconocimiento ejercicio agilidad pie izquierdo.	52
Figura 54. Agrupación de muestras referente al ejercicio agilidad pie izquierdo con PCA	52
Figura 55. Agrupación de muestras referente al ejercicio agilidad pie izquierdo con KPCA	53
Figura 56. Variación angular de la cadera en la marcha.	54
Figura 57. Ángulo en la cadera para el movimiento de marcha sujeto 1.	54
Figura 58. Ángulo en la cadera para el movimiento de marcha sujeto 2.	55
Figura 59. Ángulo en la cadera para el movimiento de marcha sujeto 3.	5
Figura 60. Ángulo en la cadera para el movimiento de marcha sujeto 4.	56
Figura 61. Velocidad angular en la rodilla para pacientes sanos y con afecciones.	56
Figura 62. Velocidad angular de la rodilla izquierda en la marcha.	57
Figura 63. Curva característica del centro de cadera en el movimiento sentarse y levantarse de una silla.....	58
Figura 64. Clasificación por fase del movimiento sentado de pie sujeto 1.....	58
Figura 65. Clasificación por fase del movimiento sentado de pie sujeto 2.....	59
Figura 66. Clasificación por fase del movimiento sentado de pie sujeto 3.....	59
Figura 67. Clasificación por fase del movimiento sentado de pie sujeto 4.....	60
Figura 68. Curva característica en la pronación y supinación de las manos.....	60
Figura 69. Clasificación del movimiento generado a partir de la alternación de las manos sujeto 1.	61
Figura 70. Clasificación del movimiento generado a partir de la alternación de las manos sujeto 2.	61
Figura 71. Clasificación del movimiento generado a partir de la alternación de las manos sujeto 3.	62
Figura 72. Clasificación por fase de movimiento en la alternación de las manos	62
Figura 73. Clasificación por fase de movimiento en la agilidad de la pierna derecha.....	63
Figura 74. Clasificación por fase de movimiento en la agilidad de la pierna izquierda.	64

Índice de Tablas

Tabla 1 Criterios clínicos del Banco de Cerebros de la Sociedad de Enfermedad de Parkinson del Reino Unido	12
Tabla 2 Ítems evaluados en la escala unificada de la enfermedad de Parkinson	14
Tabla 3 Especificaciones técnicas de Microsoft Kinect.....	18
Tabla 4 Estructura de una matriz de confusión	25
Tabla 5 Articulaciones a manipular	37
Tabla 6 Resultados de validación de las muestras adquiridas para la marcha	43
Tabla 7 Resultados de validación de las muestras adquiridas en el ejercicio sentado de pie	45
Tabla 8 Resultados de validación de las muestras adquiridas en el ejercicio alternacion manos	47
Tabla 9 Resultados de validación de las muestras adquiridas en el ejercicio agilidad pie derecho	49
Tabla 10 Resultados de validación de las muestras adquiridas en el ejercicio agilidad pie izquierdo.....	51

Glosario

Definición de los términos empleados en el documento:

- **EP:** Enfermedad de Parkinson.
- **GPe:** Globo pálido externo.
- **GPI:** Globo pálido interno.
- **SNc:** Sustancia negra compacta.
- **SNr:** Sustancia negra reticulada.
- **NST:** núcleo sub talámico.
- **FR:** Factor de riesgo.
- **TC:** Tomografía computarizada.
- **UKPDSBB:** UK Parkinson's Disease Society Brain Bank.
- **UPDRS:** Unified Parkinson's disease Rating Scale.
- **ISB:** International Society of Biomechanics.
- **FPS:** Fotogramas por segundo.
- **PCA:** principal component analysis.
- **K-PCA:** Kernel-principal component analysis.
- **Knn:** K-nearest neighbors.
- **ACC:** Accuracy.
- **TPR:** Sensitivity.
- **TNR:** Specificity.
- **FPR:** False Positive Rate.
- **FNR:** False Negative Rate.
- **MCC:** MatthewsCorrelationCoefficient.
- **PPV:** Presición o valor predictivo.
- **E:** Error de validación

Nomenclatura

<u>Conjuntos:</u>	
F	Matriz de muestras aleatorias, indexados por la letra j
B	Numero de sujetos, indexados por la letra n
M	Matriz de muestras aleatorias, indexados por la letra j
R	Matriz de correlación muestral, indexados por las letras i,j
K	Matriz del Kernel gaussiano
<u>Parámetros:</u>	
X	Eje de orientación con relación al plano coronal del cuerpo
Y	Eje de orientación con relación al plano sagital del cuerpo
Z	Eje de orientación con relación al plano transversal del cuerpo
k	Número de iteración para la validación k-fold
E	Error de validación
P	Observación positiva
N	Observación negativa
TP	Verdadero positivo
TN	Verdadero negativo
FP	Falso positivo
FN	Falso negativo
σ	Parámetro del Kernel Gaussiano
\overrightarrow{VG}	Vector centro de gravedad
<u>Variables:</u>	
λ_a	Valor propio, indexado por la letra a
p_a	Vector propio, indexado por la letra a
θ_i	Ángulo entre segmentos
d_{ac}	Distancia de articulación a centro de cadera
d_{cc}	Distancia de articulación a centro de gravedad
β_i	Ángulo entre eje de orientación en dirección x
φ_i	Ángulo entre eje de orientación en dirección y
ω_i	Ángulo entre eje de orientación en dirección z

1 Introducción

1.1 Descripción del problema

La enfermedad de párkinson EP se produce por la muerte de neuronas de la sustancia negra que es la encargada de producir la dopamina cuya única función es controlar el movimiento del cuerpo [1]. Esta enfermedad se diagnostica clínicamente por un historial médico y a través de un examen neurológico denominado UPDRS (Unified Parkinson's Disease Rating Scale) el cual es una escala unificada para la evaluación de la enfermedad de párkinson y es realizado por un especialista en neurología [2]. Este análisis es de carácter subjetivo, determinado de forma cualitativa y arbitrariamente, siendo esta la razón por la cual muchas personas son mal evaluadas y posteriormente obtienen un mal diagnóstico [3]. En la literatura se encuentran propuestas para obtener un diagnóstico de forma cuantitativa analizando la marcha de pacientes utilizando técnicas computacionales donde se emplean algoritmos reducción de dimensión como PCA y técnicas de clasificación del área de aprendizaje de máquina para obtener una clasificación, pese a esto no se ha automatizado el proceso de evaluación de los ejercicios específicos del estándar UPDRS que tienen relevancia con el aspecto motor. Con base en lo anterior se plantea la siguiente pregunta a investigar:

¿Cómo se puede diseñar e implementar un protocolo por medio del cual las técnicas computacionales del machine learning como PCA y algoritmos de clasificación como K-nearest neighbors optimicen el porcentaje de clasificación de un sistema automático para la evaluación de la enfermedad de párkinson a través del análisis de marcha utilizando Kinect y automatizando las pruebas físicas de la escala Unified Parkinson's Disease Rating Scale?

1.2 Justificación en términos de necesidades y pertinencias.

Los pacientes con la enfermedad de párkinson son de un gran interés a nivel clínico en el mundo, su calidad de vida es preocupante y a través del tiempo la importancia de los síntomas motores y no motores toman un gran papel, las personas se someten a tratamientos buscando una mejoría en pro de un bienestar, pero estos procesos no son muy efectivos [4]. En el mundo es difícil tener una cifra exacta de pacientes con esta enfermedad (EP), la fundación para la enfermedad de párkinson, afirma que hay más de 10 millones de personas en el mundo con esta enfermedad, siendo EE.UU, China, Japón y España los países con más pacientes que presentan diagnóstico, además las alarmas están encendidas ya que la población europea posee un fenómeno de envejecimiento poblacional que puede afectar estas cifras ya que esta enfermedad aparece en esta etapa de la vida [5]. Hasta el momento las técnicas computacionales para el diagnóstico cuantitativo que se han implementado en la literatura, no han obtenido resultados deseados debido a factores como la resolución de los equipos de captura como se mencionó anteriormente, por esta razón se pretende utilizar la técnica computacional análisis de componentes principales PCA y el algoritmo de clasificación Knn para obtener un porcentaje óptimo de clasificación el cual pueda generar un diagnóstico automatizado con base en el análisis de marcha capturando los datos y variables de movimiento que es observado mediante el Kinect.

1.3 Objetivos.

1.3.1 Objetivo general.

- Diseñar e implementar un sistema de evaluación del movimiento de manera cuantitativa en pacientes, mediante un protocolo basado en la escala unificada para la evaluación de pacientes con párkinson (UPDRS), donde se puedan extraer características físicas mediante el dispositivo Microsoft Kinect como sensor de adquisición, posteriormente hacer un tratamiento computacional para generar una clasificación de las muestras adquiridas en donde se pueda establecer la fase de un movimiento correspondiente a la actividad física realizada, propuesta por el estándar.

1.3.2 Objetivos específicos.

- Diseñar un protocolo, según los ítems de la escala unificada para la evaluación de pacientes con párkinson (UPDRS) que puedan ser evaluados por medio del análisis de marcha y algunos ejercicios físicos descritos en el ítem 3 del estándar correspondiente al aspecto motor.
- Definir una metodología para la medición de las variables físicas a estudiar, de manera que sean capturadas por medio del Kinect para cada uno de los ejercicios o técnicas seleccionadas del UPDRS.
- Implementar un módulo de software que a partir de las coordenadas 3D de las articulaciones calcule las variables físicas según el ejercicio realizado.
- Implementar un módulo de software que a partir de las variables y características obtenidas, determine una clasificación de la fase de movimiento correspondiente a la actividad física realizada.
- Cuantificar el error que presente el software implementado, describiendo factores de exactitud y desviación estándar de los datos desarrollados para generar la clasificación mediante un algoritmo de validación cruzada.

1.4 Marco de antecedentes.

En la literatura se han realizado diferentes propuestas de análisis sobre la enfermedad de Parkinson, tanto a nivel de desarrollo clínico, como a nivel de desarrollos tecnológicos, en donde interactúa un paciente con equipos tecnológicos como sensores, cámaras entre otros, con el fin evaluar y valorar el estado de un paciente con esta patología a través del tiempo. Por consiguiente se presentarán algunos trabajos realizados. La universidad Estatal de Pensilvania, realizó un estudio sobre la estimación de la antropometría de un sujeto a través de múltiples dispositivos Microsoft Kinect con el fin de estimar un tamaño preciso del cuerpo. El efecto consistió en promediar las estimaciones de distintas alturas para los distintos sensores, el proceso reflejó un promedio los tres sensores que se ubicaron de forma frontal, el cual se utilizó para mejorar un poco la Exactitud de la estimación. Sin embargo en algunos casos, la precisión para algunas posturas fue de carácter erróneo. Para la captura de estos datos, se dispuso de un sensor delante y detrás para un participante, fue suficiente para la estimación de la altura [6], mediante el proceso de captura a distintas posturas como se muestra en la figura 1.




Figura 1. Metodología propuesta de la captura de la antropometría, Universidad estatal de Pensilvania [6].

En el marco de séptima conferencia internacional IEEE EMBS sobre la ingeniería neural realizado en Francia, se abordó la temática sobre el reconocimiento de posturas y el análisis de marcha en pacientes con la enfermedad de Parkinson utilizando un dispositivo de captura como Microsoft Kinect, donde se enfocaron en el monitoreo de síntomas presentados en esta patología indicando mediante un análisis posicional el comportamiento de un paciente en un evento simulado patológicamente. La conclusión de este trabajo fue que el rendimiento del sistema puede ser mejorado, pues todavía no cuenta con una exactitud significativa que valide la información, por lo que se propone trabajar con la nueva versión lanzada de Microsoft Kinect, capaz de proporcionar aún más los niveles de exactitud en su información [7].




Figura 2. Reconocimiento de movimiento por fase ejecutada [7].

Diferentes estudios han desarrollados enfoques no solamente a la enfermedad de Parkinson. Un caso muy particular es el estudio del análisis de la marcha en pacientes para las diferentes actividades que pueda generar [8]. De igual forma se debe tener en cuenta que este de una u otra forma se relaciona con la patología. En la revista Neuronal Computing and Applications, se registró un trabajo gracias al sensor de profundidad que utiliza el dispositivo Microsoft Kinect para la detección de trastornos en la marcha. El procesamiento incluye la selección de segmentos de marcha y el filtrado de datos para la estimación de las características de marcha seleccionadas [8], como se indica en la figura 3. Por otro lado, se discuten los posibles aumentos adicionales en la precisión de clasificación a través de biosensores y características corporales adicionales.




Figura 3. Evolución temporal del centro de masa y piernas en la marcha a nivel tridimensional [8].

Otro artículo publicado en la revista Biomedical Engineering Online presenta el trabajo relacionado al reconocimiento de trastornos de la marcha seleccionados tanto en el entorno clínico como en el cotidiano capturado con un dispositivo digital. Los resultados obtenidos incluyen una evaluación de la longitud de las piernas, con una diferencia media, en un conjunto de n individuos estudiado. La combinación de ambas características permitió el uso de redes neuronales para hacer una clasificación y evaluación de la selectividad teniendo en cuenta los factores de especificidad y la precisión [9], como se indica en la figura 4. Pese a esto, se concluye que la síntesis de datos a partir de un mayor número de biosensores producirá patrones de matriz que se pueden utilizar para proporcionar una clasificación más precisa en una amplia gama de valores de criterio y proporcionar herramientas para el diagnóstico remoto y el procesamiento de datos, además de realizar esta clasificación a partir de otros tipos de algoritmos propuestos en la literatura.

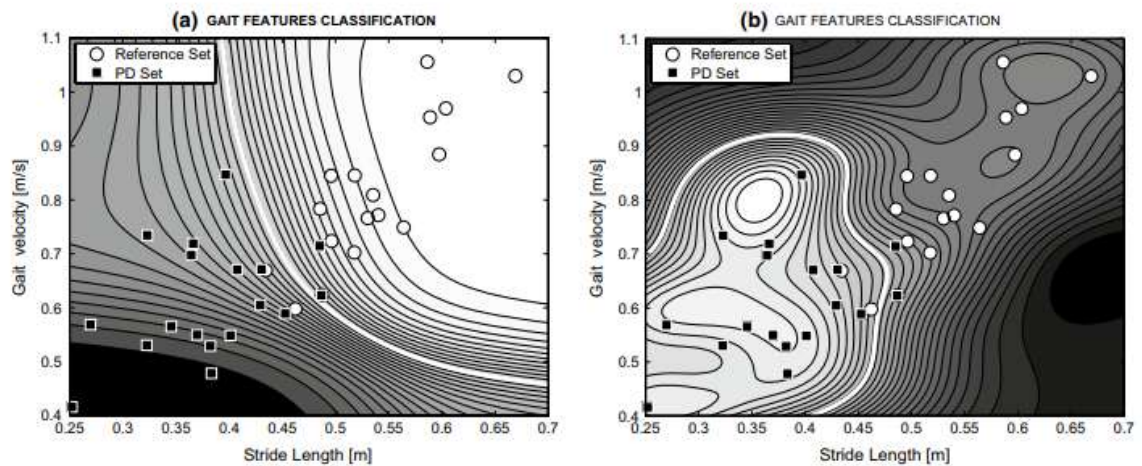


Figura 4. Clasificación de velocidad de marcha por algoritmos de redes neuronales [9]

2 Marco Teórico.

2.1 Enfermedad Del Parkinson.

La enfermedad de Parkinson (EP) es una enfermedad neurodegenerativa que resulta incurable, la cual afecta el sistema nervioso central afectando mecanismos de control y posterior degeneración de las neuronas situadas en la sustancia negra. Esto ocurre cuando no se produce una suficiente cantidad de dopamina, que es la encargada de permitir la propagación del impulso eléctrico entre neuronas, coordinando la generación de movimientos en las diferentes posturas que adopta el cuerpo [10].




Figura 5. Sistema dopaminérgico [11].

Se considera que esta enfermedad afecta principalmente el sistema motor, aunque de igual forma se produce una afectación en sistemas no motores, como es el caso de los problemas neuropsiquiátricos afectando el estado de ánimo, cognición, alteraciones del comportamiento o pensamiento, además también se presentan afecciones cognitivas como problemas sensoriales (especialmente el sentido del olfato) y del sueño, también son comunes. Algunos de estos síntomas no motores pueden estar presentes en el momento del diagnóstico [12].

El deterioro de la dopamina crea una desorganización de todas las células nerviosas del corpus striatum, lo que hace que una persona que presente esta patología no pueda controlar y administrar sus movimientos de modo natural. Hay estudios que señalan que los pacientes afectados por la enfermedad de Parkinson tienen una pérdida del 80 % de células productoras de dopamina [13]. No se conoce la causa exacta del deterioro celular, aunque hay diversas teorías que hablan del daño oxidativo, toxinas ambientales, predisposición genética y envejecimiento acelerado.

La EP se encuentra en el segundo lugar de trastorno neurodegenerativo más frecuente, solo es superado por la enfermedad del Alzheimer. Este padecimiento fue descrito por primera vez por el cirujano y farmacéutico James Parkinson en el año de 1817 en Inglaterra, este la denominó en primera instancia como parálisis agitante [14].

2.1.1 Referencia histórica.

Desde la antigüedad se relacionan algunos antecedentes patológicos que conciernen una enfermedad de trastorno al aspecto motor de una persona, pese a esto no se tiene una evolución cronológica de la EP en el desarrollo evolutivo en la humanidad. Con la descripción de James Parkinson, en 1880 se originaria una definición sobre la rigidez asociada con la parálisis agitante asociada a diferentes pacientes detallados de la época.

En el año 1875 el francés Jean-Marie Charcot y su colega ingles Edme Felix Alfred Vulpian indagaron sobre las alteraciones cognitivas por lo general en las facultades psíquicas, estas serían afectadas. En 1880 Charcot promulga por primera vez la rigidez asociada con la parálisis agitante. A raíz de estos avances, se Charcot instauró investigaciones sobre el temblor en pacientes con esclerosis en placas, distinguiendo el temblor de estos sujetos del de la parálisis agitante; señalan la posición de las manos y el tipo de escritura como elementos semiológicos para su distinción [15]. Tiempo después, Santiago Ramón y Cajal y Charles Sherrington diferenciaron la sustancia negra, globus palidus, tálamo y otros, que se agruparon se debía a una deficiencia en la sustancia negra. En 1956 Arvid Carlsson, propuso un modelo experimental de parkinsonismo en conejos tratados con reserpina. Estableció que la noradrenalina y la molecula de dopamina, indicada en la figura 6, estaban reducidas y sostuvo que la dopamina era un neurotransmisor y los parkinsonianos se debían a su disminución, este descubrimiento le generó el premio Nobel en el año 2000 [15].



Figura 6. Molécula de dopamina [16].

En 1960 Hornykiewicz y Birkmayer manifestaron que los cerebros parkinsonianos tenían 80 a 90% menos dopamina. La dopamina era conocida desde 1913 gracias a Marcus Guggenheim, pues este fue el encargado de sintetizarla. En 1967 George Constantin Cotzias la administró como precursor L Dopa en dosis progresivas por vía oral, obteniendo un método terapéutico efectivo. Fue, en la década de 1960 cuando los investigadores identificaron un defecto cerebral fundamental que es el distintivo de la enfermedad: la pérdida de células cerebrales que produce un neurotransmisor, La dopamina, como parte fundamental en los circuitos cerebrales implicados en el monitoreo del movimiento. Desde esta época en adelante, se han experimentado diferentes compuestos, pero la L-Dopa o sus combinaciones,

incluyendo la cirugía en sus diversas modalidades, sigue siendo el pilar terapéutico para el tratamiento de esta anomalía [15].

A pesar de que se ha logrado un mejor control sobre los pacientes afectados con esta insuficiencia, la cual han optado con objetivos para prolongar la esperanza de vida los efectos siguen siendo indeseables, pues no se ha encontrado una medicina que acabe con esta anomalía, es por eso que se mantiene la búsqueda del tratamiento idealmente curativo para esta enfermedad de trastorno neurodegenerativo [15].

2.1.2 Epidemiología.

Se ha abordado diferentes estudios epidemiológicos y genéticos de la EP, ya que estos exhiben conflictos metodológicos puesto que la determinación de factores para el diagnóstico se realiza a través de un orden cronológico y clínico, debido a que en los hallazgos del análisis físico y mental, en un solo chequeo no se puede evidenciar esta anomalía sin que aún exista un marcador biológico válido. Hay un estimado de 5% a 20 % para los casos de mal diagnóstico clasificados como pacientes con EP al compararlos con el diagnóstico definitivo histopatológico. Los errores diagnósticos más frecuentes son: temblor esencial, parkinsonismo vascular y otros cuadros atípicos [17].

Esta enfermedad se manifiesta entre los 60 y 70 años, también se tiene presente que personas menores de 40 años no son afectados por la EP. En general, se tiene en cuenta que el 1% y 2% de la población mayor de 65 años padece la EP, manifestándose hasta un 5% en las personas mayores a los 85 años. La incidencia de EP se evidencia en su mayor parte en los hombres, se habla que entre 1,5 y 2 veces más con relación a las mujeres [17]. Esto es especialmente evidente entre los occidentales, ya que los estudios en la población oriental han fallado en replicar dicha diferencia. Por otro lado, se tiene que la tasa de mortalidad de los pacientes afectados por esta patología se estima entre 10 a 20 años a partir del instante de manifestación de la enfermedad [18].

Esta patología se suele caracterizar por la alteración en los aspectos motores del cuerpo, manifestándose en presencia de temblor en un reposo, rigidez, bradicinesia y alteración en las diferentes posturas optadas por la persona. Uno de los motivos de consulta en los inicios de esta enfermedad es el temblor en reposo, presentando un 70% [19].

2.1.3 Fisiopatología

En la EP existe una pérdida neuronal debido al cambio de pigmentación que se exhibe en la sustancia negra y en los núcleos subcorticales pigmentados, en los cambios que se producen en la sustancia negra análogamente origina una reducción de moléculas de dopamina en el estriado. La zona en donde se encuentra compactada la sustancia negra contiene la mayor información de los cuerpos dopaminérgicos del cerebro, es allí en donde se observan las lesiones producidas a nivel cerebral en los pacientes debido a las alteraciones en la vía dopaminérgica nigroestriatal [20]. La dopamina es sintetizada en el estriado donde se terminan las neuronas dopaminérgicas y donde se encuentran los cuerpos celulares en la sustancia negra, es allí donde estas terminaciones nerviosas se adhieren al neurotransmisor

dentro de las vesículas para ser liberados en el espacio sináptico cuando las células se disparan [20].

A nivel neuronal, la afección en el estriado compromete complejamente el aspecto motor respecto a la relación entre los ganglios basales y los lóbulos frontales, siendo este un circuito motor el encargado de los parámetros que generan los movimientos, las anomalías que se encuentran en la EP como el temblor, la rigidez o la bradicinesia, se deben a la baja actividad dopaminérgica producida en este circuito [21], las sintomatología en las afecciones posturales y de equilibrio se deben a la degeneración de los cuerpos celulares de la sustancia negra [22].

El estudio genético ha tomado mayor importancia en el momento de conocer la fisiopatología de la EP, ya que analiza el metabolismo de las proteínas ubiquitina y alfa sinucleína, que al agregarse de manera anormal forman los cuerpos de Lewy [17]. La guía hipocinetica en la cual se manifiesta el déficit de dopamina estipula en la vía indirecta una desinhibición del núcleo subtalámico y en la vía directa una desinhibición del globo pálido interno [17]. Ello daría como resultado una inhibición de la actividad eferente del tálamo a la corteza motora, que disminuiría su excitabilidad explicando parcialmente la fisiopatología y fenomenología clínica del parkinsonismo [17] como se ilustra en la figura 7.

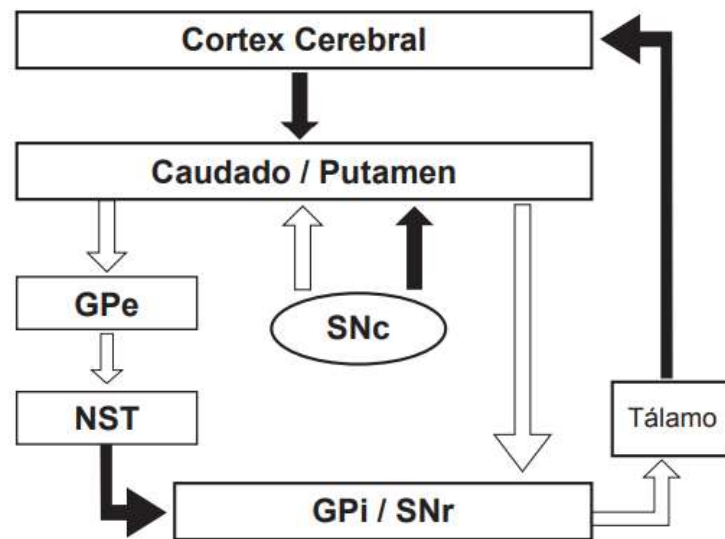


Figura 7. Esquema funcional normal de los ganglios basales [17]

En la guía normal del circuito motor o putamen de los ganglios basales, la dopamina estimula las neuronas (GABA)/Sustancia P (vía directa) e inhabilita las neuronas GABA/encefalina (vía indirecta), generando un control en el balance entre la vía que estimula el movimiento y la vía que inhibe el movimiento figura 4.

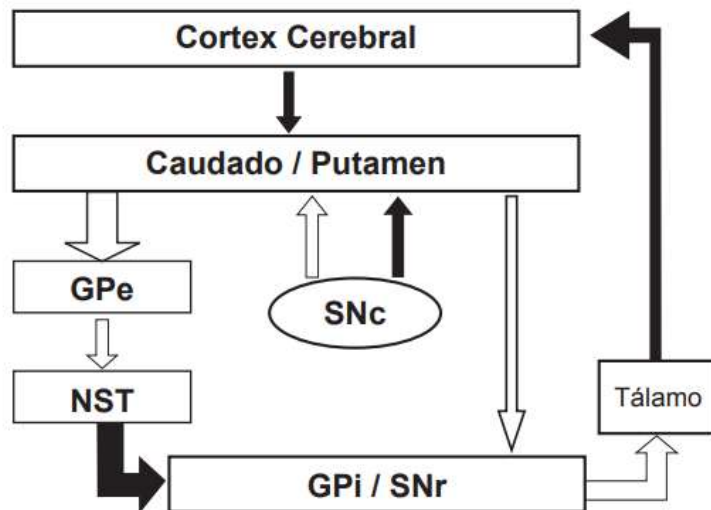


Figura 8. Esquema funcional parkinsonismo de los ganglios basales [17]

GPe: Globos pálido externo, GPI: globos pálido interno, SNc: Sustancia negra compacta, SNr: Sustancia negra reticulada, NST: núcleo sub talámico.

Por otro lado, las lesiones de tipo neurodegenerativo, no evolucionan paralelamente, pero pueden ser de carácter adictivo y potencian una en término de otra como expresión funcional. La variedad de las lesiones que se presentan a nivel neuronal en la EP pueden ser indagadas como una gran variedad de sintomatología en el aspecto motor, pero teniendo en cuenta que hay alteraciones cognitivas [23].

2.1.4 Diagnóstico

En la actualidad no existe una forma de diagnosticar la EP, debido a que no se conoce una prueba específica que evalúe detalladamente la condición física con relación al estado cognitivo de una persona, análogamente la sintomatología en las primeras fases de la enfermedad es muy leve y poco específica. Para el estado de un paciente con EP, se plantea dos fases distinguibles para la enfermedad, la fase pre sintomáticas y la fase sintomática [24]. Los signos que afectan temprana edad el aspecto motor específicamente en el movimiento son temblor, rigidez muscular y lentitud, como se indica en la figura 9, 10, 11. Los factores que se tienen en cuenta en esta etapa pueden ser [25]:

- Síntomas que comienzan en un lado del cuerpo
- Cambio en la expresión facial (mirada fija, ausencia de parpadeo)
- Falla en balancear un brazo cuando camina
- Posición encorvada
- Hombro congelado, con dolor
- Cojera o arrastre de una pierna
- Adormecimiento, hormigueo, dolor o incomodidad en el cuello o las extremidades
- Voz suave

- Escritura pequeña
- Sensación de temblor interno
- Pérdida del sentido del olfato
- Depresión o ansiedad



Figura 9. Registro de temblor en un paciente con EP [17].



Figura 10. Postura en flexión de un paciente con EP [17].



Figura 11. Mano estriada y pie deforme de un paciente con EP [26].

A pesar de estas anomalías, la EP presenta diferentes ramas separadas como factores de riesgos (FR) que se deben tener en cuenta en el momento de realizar un previo diagnóstico de la enfermedad [27]. Un FR muy particular es la edad, aunque no se tiene como previsto que la enfermedad sea a partir de una edad establecida, este es determinante ya que en la mayoría

de los casos las manifestaciones de esta enfermedad se hace presente, análogamente mientras transcurre el tiempo esta patología se hace más fuerte provocando un mayor deterioro [28].

Otro FR el cual está vinculado a la EP es el sexo del paciente, puesto que, según diferentes estudios, hay una relación de prevalencia de esta patología según el sexo la cual indica que los hombres son más propensos a padecer la EP ya que por cada mujer con esta enfermedad, tres hombres la sufren [29]. Entre múltiples FR que se desarrollan para la EP uno que toma mayor importancia es el factor genético puesto que se demuestra a través de historia clínica de familiares se puede establecer una relación en la transmisión de esta anomalía en la base genética [27]. Clásicamente el diagnóstico de la EP es efectuado por un especialista en la salud en el área de la neurología, este diagnóstico a menudo puede ser erróneo tanto así que se habla de una cifra de que oscila entre el 35% en la fase inicial de manifestación de la patología y un 24% en el momento de diagnóstico definitivo [30]. Un chequeo temprano con un especialista permite evaluar al paciente a través del tiempo, pues este se examina observando los avances de la patología y análogamente permite la estrategia adecuada de tratamiento terapéutico.

Desde el punto de vista clínico se han utilizado el criterio del Banco de Cerebros de Reino Unido (United Kingdom Parkinson's Disease Society Brain Bank UKPDSBB) [31], este se ha caracterizado por ser confiable, además de ser aceptado como estándar en ensayos clínicos y proyectos de investigación [32]. Para el diagnóstico clínico definitivo se analiza [32] la existencia por más de un año los tres signos motores cardinales de la patología donde se manifiestan temblor de reposo, rigidez y bradicinesia. Además de la respuesta a la administración de levodopa (el precursor metabólico de la dopamina), el cual genere una mejoría clínica en un rango de 30% al momento de evaluación respecto a la escala UPDRS. Los criterios de supresión son [32]:

- curso remitente.
- tratamiento con neurolépticos.
- progresión.
- exposición a drogas o toxinas con conocido efecto parkinsoniano.
- historia de encefalitis.
- parálisis supra nuclear (parálisis de mirada vertical, hacia abajo o lateral).
- signos cerebelosos.
- signos de afectación de la neurona motora inferior.
- demencia desde el comienzo de la enfermedad.
- inestabilidad postural.
- evidencia de enfermedad vascular cerebral.

Los Criterios diagnósticos descritos por el Advisory Council of the National Institute of Neurological Disorders and Stroke, N.I.H [33], se tienen en cuenta en los siguientes parametros [32], como se indica en la tabla 1.

- Temblor en reposo para los signos motores cardinales (3-7 Hz) frecuencia: 69- 100 %.
- Rigidez con frecuencia entre 89-99 %.
- Bradicinesia con frecuencia entre 77-98 %.
- Inicio asimétrico con frecuencia entre 72-75 %.
- Síntomas atípicos que generan exclusión: inestabilidad postural en los años iniciales, congelamiento precoz, parálisis en la mirada vertical, evidencia grave de daños a partir de la farmacoterapia.

Síntomas esenciales para el diagnóstico del síndrome Parkinsoniano	Criterios de exclusión para el DX de la EP antecedentes de ACV repetido, progresión escalonada de signos Parkinsonianos	Criterios que apoyan el diagnóstico de EP (se requieren tres o más para el diagnóstico definitivo)
Bradicinesia (lentitud en la iniciación del movimiento voluntario, progresiva reducción en velocidad y amplitud de acciones repetitivas).	Antecedentes de TCE repetido, de encefalitis, crisis oculogiras; uso de neuroléptico al inicio de los síntomas; más de un pariente afectado; remisión sostenida.	<ul style="list-style-type: none"> • Comienzo unilateral. • Temblor de reposo. • Cuadro progresivo. • Asimetría persistente que compromete más el lado donde comenzó
Por lo menos uno de los siguientes: •Rigidez •Temblor de reposo de 4 a 6 HZ •Inestabilidad postural no causada por compromiso visual, vestibular, cerebeloso o propioceptivo	Síntomas unilaterales luego de 3 años de evolución: •Parálisis supra nuclear de la mirada • Signos cerebelosos. •Compromiso autonómico temprano y severo. •Demencia precoz con trastornos amnésicos del lenguaje y praxia. •Signo de babinski. •Presencia de un tumor cerebral o hidrocefalia comunicante en la TAC. •Falta de respuesta a dosis adecuadas de levodopa (si se excluye malaabsorción). • Exposición a MPTP.	<ul style="list-style-type: none"> •Excelente respuesta (70-100 %) a la levodopa. •Corea severa inducida por levodopa. •Respuesta a la levodopa de 5 años o más. •Curso clínico de 10 años o más

Tabla 1. Criterios clínicos del Banco de Cerebros de la Sociedad de Enfermedad de Parkinson del Reino Unido [31].

Otro método de diagnóstico es el diferencial, en donde se tiene en cuenta el temblor esencial TE y el parkinsonismo vascular. Hay diversas formas de TE como aportes clínicos: frecuentemente, con antecedentes familiares; temblor predominantemente de acción; ausencia de otros signos poca rigidez; escasa o lenta progresión, ausencia de respuesta terapéutica a la levodopa. El parkinsonismo vascular, como otra fuente de origen (hidrocéfalo normotensivo, fármacos neurolépticos, tóxicos), se pueden inferir fundamentándose en anamnesis y haciendo uso del diagnóstico a través de neuroimágenes [34]. Un método actual para el

diagnóstico es el de tipo genético, en este se utiliza la aproximación geneticomolecular para realizar la comprensión de las causas y los mecanismos de la EP y de muchas otras enfermedades neurodegenerativas. Este método se caracteriza por una notable heterogeneidad etiológica [35].

En la actualidad se está desarrollando otros métodos de diagnóstico a través neuroimágenes estructurales y funcionales por medio de la cuantificación del grado de degeneración neuronal del sistema dopaminérgico estriatal, este se puede evidenciar en el diagnóstico diferencial en donde se analizan otras formas de parkinsonismo [36]. Las metodologías empleadas para este tipo de diagnóstico por imágenes son:

- **Tomografía computarizada:** la tomografía computarizada cerebral (TC) no refleja anomalías significativas de la EP; sin embargo, por medio de esta se pueden derivar distintos factores de origen secundario que se evidencian en un cuadro clínico como la hidrocefala normotensivo, lesiones vasculares o de otra naturaleza). Los tipos de tomografía utilizados son: tomografía computarizada por emisión de fotones y tomografía computarizada por emisión de positrones [34].
- **Resonancia Magnética:** La resonancia magnética (RM) cerebral permite observar a veces una hipointensidad de la pars compacta de la sustancia negra, un indicador de la patología en pacientes con la EP o con parkinsonismo atípico, la relevancia clínica es que los estudios en pacientes exponen la degeneración estriatonígrica.

2.1.5 Escala unificada de clasificación de la enfermedad de Parkinson UPDRS.

El test Unified Parkinson's Disease Rating Scale' UPDRS, es una herramienta de medida para estudios clínicos en pacientes con al EP la cual fue desarrollada para la evaluar detalladamente el estado de discapacidad de los pacientes a través de la evolución gradual de la enfermedad [37]. Fue desarrollada en el año 1984 por el comité dirigido por el profesor Stanley Fahn [38]. Este protocolo evalúa cuatro áreas de discapacidad primaria, y dos áreas similares de escalas de unificación, que se indican a continuación:

- Parte I: evaluación del estado cognitivo, mental, comportamiento y estado de ánimo.
- Parte II: evaluación de las actividades realizadas diariamente en las que se incluyen el habla, la deglución, la escritura a mano, la higiene, la caída, la salivación, el giro en la cama, el caminar y el corte de alimentos.
- Parte III: los aspectos motores evaluados por un médico especialista.
- Parte IV: dificultades en la realización de terapias.
- Parte V: estatificación de Hoehn y Yahr de la gravedad de la enfermedad de Parkinson.
- Parte VI: Schwab y escala ADL de Inglaterra.

Este estándar UPDRS presenta una calificación sistémica la cual se ha encontrado una buena fiabilidad en el proceso de interpretación del estado de la enfermedad por parte del especialista [39]. Cada ítem estimado tiene un rango de valoración que va desde 0 = normal, 1 = muy leve, 2 = leve, 3 = moderado y 4 como afección severa. En el primer aspecto evaluado, la puntuación oscila en un rango de 0 a 16 puntos, la segunda parte de la prueba

oscila en el rango de puntuación entre 0 a 52 puntos, finalmente el tercer aspecto evaluado oscila entre 0 a 108 puntos. La puntuación del UPDRS entre el aspecto I y III es de 0 a 176, donde “176” representa incapacidad total y “0” ninguna incapacidad [40]. La parte I está conformada por cuatro ítems, la parte II por 13 ítems, parte III por 14. La parte IV evalúa las complicaciones motoras y algunos de sus ítems sólo se califican como ausentes o presentes. Se debe destacar que, en la descripción original de la UPDRS, se consideraba una parte V (escala modificada de Hoehn y Yahr) y una parte VI (escala de discapacidad) [40]. El aspecto evaluado I está conformado por serie de preguntas de carácter autónomo. Las respuestas deben detallar el sentir del paciente durante la mayor parte del tiempo. En esta parte puede dar respuesta tanto el paciente como la persona que acompaña a este. El aspecto evaluado II detalla los aspectos motores con relación a las actividades cotidianas realizadas. De igual manera que en el aspecto I es de carácter autónomo, este consta de 13 preguntas. El tercer aspecto relaciona el aspecto motor detallado, está compuesta por 33 puntuaciones con base a 18 ítems. Por último, el cuarto aspecto hace referencia a seis preguntas relacionadas con las complicaciones motoras como lo son discinesias, fluctuaciones y distonía dolorosa.

Aspecto I	Aspecto II	Aspecto III	Aspecto IV
1. Deterioro cognitivo.	1. Habla.	1. Lenguaje.	1. Tiempo con discinesias.
2. Alucinaciones y psicosis.	2. Saliva y babeo.	2. Expresión facial.	2. Tiempo con discinesias.
3. Ánimo depresivo.	3. Masticación y deglución.	3. Rigidez.	3. Tiempo en estado OFF.
4 Ansiedad.	4. Comer.	4. Golpeteo de dedos de las manos.	4. Impacto de las fluctuaciones.
5. Desregulación Dopaminérgica.	5. Vestirse.	5. Movimientos con las manos.	5. Complejidad de las fluctuaciones.
6. Apatía.	6. Higiene.	6. Pronación-supinación de las manos.	6. Distonía en OFF.
7. Insomnio.	7. Congelamiento o bloqueos.	7. Golpeteo con los dedos de los pies.	
8. Somnolencia diurna.	8. Escritura.	8. Agilidad de las piernas.	
9. Dolor.	9. Pasatiempos.	9. Levantarse de la silla.	
10. Problemas urinarios.	10. Vuelta en cama.	10. Congelamiento de la marcha.	
11. Estreñimiento.	11. Temblor.	11. Estabilidad postural.	
12. Hipotensión Ortostática.	12. Levantarse.	12. Postura.	
13. Fatiga.	13. Caminar y equilibrio.	13. Espontaneidad global del movimiento.	
		14. Temblor postural de las manos.	
		15. Temblor de acción de las manos.	
		16. Amplitud del temblor de reposo.	
		17. Persistencia del temblor del reposo.	
		18. Marcha.	

Tabla 2. Ítems evaluados en la escala unificada de la enfermedad de Parkinson [40].

2.2 Estándares y recomendaciones biomecánicas.

El movimiento en el cuerpo humano se ejecuta en tres dimensiones, cada segmento del cuerpo asume posiciones y orientaciones espaciales durante la ejecución del movimiento. Para representar la posición espacial de los diferentes segmentos del cuerpo, se ha utilizado generalmente el sistema de coordenadas cartesiano con origen en el centro de gravedad del cuerpo, los movimientos se generan con respecto a los planos frontal, sagital y coronal [41]. La Sociedad Internacional de Biomecánica ISB, se ha encargado de realizar una propuesta de estandarización en el reporte de datos obtenidos a partir de la cinemática del cuerpo. Estos análisis surgen a partir de la necesidad de corroborar la información a nivel internacional sobre los estudios dedicados en el análisis espacial y cinemático que ejecuta cuerpo humano [42]. Sistema global de referencia.

2.2.1 Definición de un sistema de referencia global.




Figura 12. Marco de referencia global y segmentario a partir de los centros de masa [43].

Se denota mediante un conjunto de tres ejes de variables X, Y, Z ortogonales entre sí, el cual consta de un primer eje +Y que va en dirección paralelo al campo de la gravedad y al plano sagital el cuerpo. El eje +X y el eje se encuentran de forma perpendicular al eje +Y, en las direcciones del plano coronal y transversal [43] como lo indica la figura 8.

2.2.2 Definición de sistema de referencia local para centro de masa en segmentos.

Se define un sistema que describe la posición y orientación con respecto al sistema de referencia global en donde prevalece la regla de la mano derecha y se define el eje X como anterior, el eje Y como el proximal y el eje Z como posterior en relación con la posición anatómica estándar [43].




Figura 13. Orientación a partir del marco de referencia para cada centro de masa [43].

2.2.3 Modelo mecánico en articulaciones.

El modelo mecánico se especifica a partir de la condición de un segmento óseo o una articulación con respecto a un sistema de coordenadas global, de igual forma con un hueso no adyacente. Además, la cinemática de los segmentos es el objeto del estudio en el cuerpo para realizar un análisis biomecánico, por esta razón se debe especificar el conjunto de articulaciones o segmentos que se operaran [44], por otra parte, la cinemática en las articulaciones se define a partir del conjunto de dos segmentos adyacentes óseos.




Figura 14. Definición de sistema de coordenadas en el tórax [45]

La cinemática de rotación para una articulación se puede generar a partir de la descomposición de una matriz de rotación en torno a los ejes anatómicos predefinidos con base a coordenadas anatómicas funcionales. Para la articulación de interés, se debe especificar el número de enlaces y grados de libertad a partir de la rotación de esta, ver figura 14.

Para la definición de un sistema de coordenadas para una articulación generalmente se requiere una previa definición de dos sistemas de coordenadas, uno para el segmento proximal y otro para el segmento distal que forma la articulación. Los cuales proponen que estos dos sistemas de coordenadas sean marcos anatómicos. Sin embargo, la orientación relativa de los marcos anatómicos del segmento proximal y distal puede ser solo indicativa de las rotaciones reales de la articulación como se ilustra en la figura 14, ya que los ejes anatómicos que forman estos sistemas generalmente son solo una aproximación de los ejes reales de rotación de las articulaciones, [44]. En la cinemática de los segmentos, los sistemas

de coordenadas deben ser característicos de la anatomía del hueso. Para el análisis de la cinemática en las articulaciones o segmentos, se deben definir apropiadamente de los ángulos de Euler para formular la orientación relativa de los sistemas de coordenadas de una manera clínicamente significativa.




Figura 15. Modelo mecánico de extremidad superior [44].

2.3 Microsoft Kinect.

El dispositivo Microsoft Kinect se lanzó en noviembre de 2010 en primera medida para la consola de video juegos Xbox 360 desarrollada Microsoft. Se diferencia de los controladores diseñados por otras empresas como Sony o Nintendo, debido a que el Kinect permite a los usuarios interactuar y controlar la consola a través del movimiento de su cuerpo o mediante la pronunciación de la voz, sin la necesidad de establecer un contacto físico. Este dispositivo permite obtener en tiempo real la profundidad, color y audio de una escena [46].



Figura 16. Dispositivo Microsoft Kinect [46].

En el momento de su lanzamiento al mercado, Microsoft entendió que el uso de este dispositivo no solamente era con fines comerciales, así implementó una versión beta del kit de desarrollo de software Kinect SDK para realizar una conexión con una computadora mediante un entorno de programación cuyo propósito es potenciar áreas de aplicación e investigación como la robótica o la realidad virtual.

Este dispositivo cuenta con un sensor de profundidad, un sensor monocromático, el cual proyecta un haz de luz infrarroja IR, los cuales son los encargados de capturar imágenes en diferentes condiciones de oscuridad.

Aspectos técnicos de Microsoft Kinect				
Sensores y cámaras	Campo de Visión	Flujo de Datos	Sistema de seguimiento	Sistema de audio
Cámara RGB.	Horizontal de 57°.	320x240 a 16 bits de profundidad a 30FPS.	Rastrea hasta 6 personas, incluyendo 2 jugadores activos.	Permite chat en vivo.
Cámara VGA con Resolución de 640x480 a 30 Frames por segundo.	Vertical de 43°.	640x480 a 32 bit de color a 30FPS.	Rastrea 20 articulaciones por jugador activo.	Sistema que cancela el eco.
Doble cámara de profundidad 3D con resolución de 640x480px a 30FPS.	Rango de apertura o inclinación $\pm 27^\circ$.	Audio de 16 bit a 16kHz.		Reconocimiento de voz múltiple.
Sensor de profundidad.	Rango de profundidad= 1,2-3,5 metros			
-Micrófono multiarreglo.				

Tabla 3. Especificaciones técnicas de Microsoft Kinect [47].

2.3.1 Arquitectura de Microsoft Kinect.

El dispositivo Microsoft Kinect tiene un diseño similar a una cámara web, el cual consta de una cámara a color RGB y una cámara con IR capaz de capturar imágenes a profundidad. Además de video, el dispositivo cuenta con un grupo de 4 micrófonos para realizar captura de audio siendo capaz de aislar el ruido que se produce en el ambiente y que genera interferencia en las señales de audio, para así realizar charlas y comando de voz mediante la consola o computadora a la cual este dispositivo se encuentre acoplado. El dispositivo se encuentra en una base motorizada que es controlada mediante un acelerómetro de 3 ejes que facilita direccionarse en forma horizontal para ajustar el campo de visión del dispositivo [48].

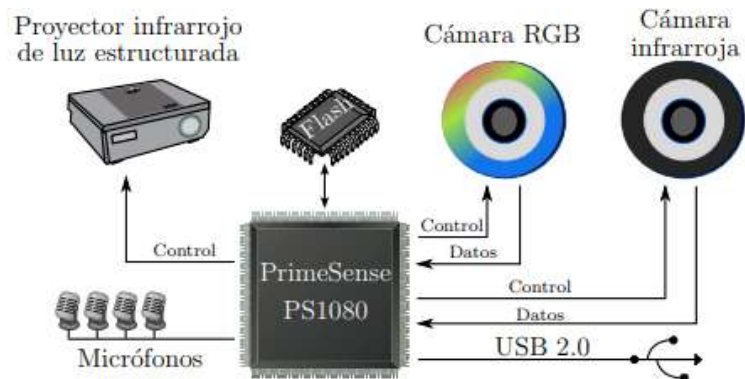


Figura 17. Diagrama de Hardware de Microsoft Kinect [48]

En la figura 17, se relaciona un diagrama con los componentes de hardware para el procesador de imagen del dispositivo Kinect. Este es operado mediante el chip PS1080, elaborado por PrimeSense, el cual realiza la generación y sincronización de las imágenes de profundidad e imágenes de color. Este chip elabora todos los algoritmos de adquisición de imágenes de profundidad a partir de un mecanismo que proyecta un patrón de puntos infrarrojos llamado LightCoding el cual irradia el cuerpo de una persona extrayendo información [46].

El dispositivo Kinect se ejecuta particularmente en una representación maestro-esclavo, el cual el maestro es la computadora y el esclavo es el Kinect. Este chip genera y mantiene en memoria los cuadros de imagen de profundidad y color a una velocidad de 30 FPS (cuadros por segundo). Este dispositivo cuenta con un puerto USB 2.0 para realizar la conexión a la consola o computadora. El procesamiento del audio y el control de USB es realizado por un microprocesador Marvell Technology que funciona independientemente al procesamiento de imágenes [48].

2.3.2 Sensores internos.

Cámara de profundidad: Esta se compone por la cámara infrarroja y el proyector infrarrojo de luz estructurada, el sensor de profundidad utiliza una tecnología de codificación por luz la cual funciona como un escáner 3D para realizar una reconstrucción tridimensional de la escena. Esta codificación desplaza una línea de luz para proyecta un patrón de puntos infrarrojos en la escena a analizar [46]. El patrón de puntos se localiza en un difusor (rejilla) frente al proyector infrarrojo. Al emitir la luz infrarroja, el patrón se dispersa por la escena, proyectándose sobre las personas y objetos presentes en ésta. El sensor de profundidad consiste en el proyector IR combinado con la cámara IR, que es un sensor semiconductor de óxido de metal (CMOS) monocromático y complementario [49].



Figura 18. Proyector infrarrojo, cámara infrarroja, cámara RGB de Microsoft Kinect [49]

2.3.3 Características de video y audio.

El dispositivo Microsoft Kinect realiza la adquisición de imágenes de video mediante un sensor CMOS de colores a una frecuencia de 30 Hz, en colores RGB de 32-bits y resolución VGA de 640×480 píxeles. El canal de video monocromo CMOS es de 16-bit, resolución QVGA de 320×240 píxeles con hasta 65,536 niveles de sensibilidad [50].




Figura 19. Funcionamiento del sensor monocromático CMOS [50]

Este dispositivo permite calcular la distancia en relación posición inicial del dispositivo y mediante el objeto situado en el entorno de la imagen, el sensor emite un haz láser infrarrojo que proyecta un patrón de puntos sobre los objetos cuya distancia se determina. Una cámara infrarroja que sirve de receptor capta el patrón y mediante el tratamiento realizado en el hardware calcula la profundidad de cada punto. El rango de profundidad del sensor de Kinect está entre 0.4 y 4 metros [50]. Existen 2 modos (Default y Near) para determinar las distancias como indica la figura 20.




Figura 20. Modo Default y Near, rango de distancia admitidas por Microsoft Kinect [50]

El dispositivo consta de cuatro cápsulas que actúan como micrófono, el cual maneja información auditiva en cada canal procesando en 16-bit de audio con una ratio de frecuencia

de 16 kHz. La cámara de Kinect funciona con hardware y software propios para el reconocimiento de imagen. La característica de video a partir de las imágenes captadas por el dispositivo tiene dos funciones principales, la primera es generar una proyección en 3D de la imagen correspondiente visual del entorno. La segunda función es reconocer las características esqueléticas presente en los seres humanos mediante un movimiento ejecutado a través de la imagen a partir de diferentes segmentos compuestos por las articulaciones del cuerpo y un esquema en escala de grises [50]. La cámara de dispositivo Kinect cumple la función de reconocer a que distancia se encuentran distintos objetos, logrando distinguir los movimientos ejecutados en tiempo real. El dispositivo Kinect puede a diferenciar la profundidad de cada objeto con una resolución de 1 centímetro y las estimaciones de la altura y anchura con una exactitud de aproximadamente 3 milímetros. El hardware de Kinect está compuesto por la cámara y el proyector de luz infrarroja, añadido al firmware y a un procesador que utiliza algoritmos para procesar las imágenes tridimensionales [50].

2.3.4 Ángulo de visión.

El dispositivo genera una imagen de 640x480 pixeles, en donde el ángulo de vista horizontal oscila entre 0 y 57°, análogamente el ángulo de vista vertical oscila entre 0 y 43° como lo indica la figura 17.




Figura 21. Ángulo de visión vertical y horizontal del dispositivo Microsoft Kinect.

Un factor importante en el dispositivo Kinect es que cuenta con un pivote que actúa como eje central entre la base y el marco que contiene los sensores, el cual puede generar un ángulo de apertura vertical que oscila entre -27° y 27°.

2.3.5 Detección y captura de esqueleto con Microsoft Kinect

El dispositivo Microsoft Kinect realiza la captura de información por medio del sensor de profundidad, en la imagen a color se visualiza la información a partir de la distancia y contorno en que se puede encontrar el objeto o usuario, esta imagen es examinada por parte del software al interior del dispositivo realizando una segmentación del objeto o sujeto considerado para extraer información precisa a partir de puntos producidos por la segmentación con el fin de especificar por medio de la fracción la información detallada del objeto o usuario capturado [46]. Un ejemplo de esta información puede ser su posición o postura realizada. Al interior del dispositivo esta implementado un software

que desarrolla un algoritmo de detección, el cual consiste en fraccionar el cuerpo del objeto o usuario en 31 partes proyectadas en un plano tridimensional, como se representa en la figura 22.




Figura 22. Segmentación y obtención de articulaciones a partir de imagen profundidad [49].

Si bien la imagen a color refleja una mayor aproximación a la visualización del entorno, la imagen de profundidad tiene mayores beneficios y ventajas para ejecutar un análisis en la imagen, las imágenes de profundidad proporcionan mayor calidad en condiciones ambientales ligeras, la luz solar que se incide en el entorno no afecta el sistema. Esto hace que el sensor realice muestras de dichas imágenes a través de la cámara de profundidad y estas sean más fáciles de analizar que las imágenes a color [51].

La segmentación de la imagen del cuerpo del usuario para diferentes imágenes utiliza un clasificador cuyo algoritmo está basado en un árbol de decisiones. Este algoritmo utiliza una base de datos con una postura equivalente en cada imagen, aproximadamente 100 000 poses para cada imagen. Para establecer la decisión de que imagen presenta similares particularidades a partir de las características pre visualizadas por cada imagen. Cuando una persona se pone en frente al Kinect, este detecta el contorno de su cuerpo e identifica la posición de 20 articulaciones del cuerpo en un espacio 3D, como lo indica la figura 22, La persona se mueve frente a Kinect, realiza un seguimiento de las posiciones de cada articulación. Estas posiciones se calculan 30 veces por segundo (fps), generando un modelo denominado skeletal tracking [49].

Una característica está definida como una función de densidad $f(l,x)$ que define una imagen l y una posición x , además de un parámetro θ que describe las características de la imagen dentro del espacio tridimensional, a través de estas características, el algoritmo detecta que imagen se asemeja a la imagen almacenada dentro de la base de datos. A partir de este algoritmo el sensor obtiene articulaciones o puntos específicos del cuerpo del usuario. La detección de articulaciones es demasiado precisa, con un 91,4% de probabilidad de ser localizados correctamente dentro del plano tridimensional [46]. Para obtener las articulaciones del cuerpo del usuario se llevan a cabo tres pasos [51]:

- Un estimador de densidad por cada parte del cuerpo del usuario, basado en la probabilidad de la superficie del área de cada pixel.
- Técnica para encontrar eficiencia en la densidad.
- Algoritmo que obtiene la aproximada localización de los puntos o articulaciones.

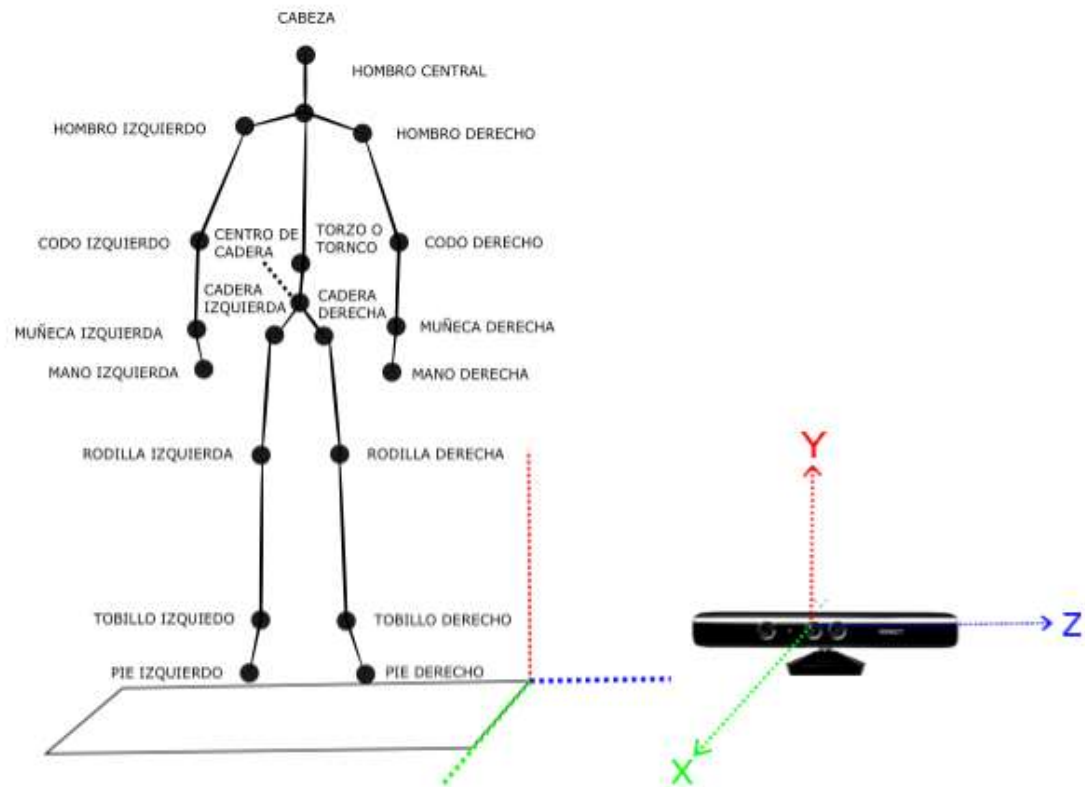


Figura 23. Representación de articulaciones en Microsoft Kinect.

2.4 Aprendizaje de máquina.

2.4.1 Algoritmo de validación K-fold y matriz de confusión.

Algoritmos de validación cruzada: en los diferentes estudios desarrollados a partir de técnicas de aprendizaje de máquina supervisado se implementan algoritmos de validación para encontrar el mejor algoritmo que presente el menor error estimado con el fin de extraer conclusiones estadísticamente convenientes y así resolver la tarea en cuestión [52].

La validación cruzada por número de iteraciones k-folds es una técnica utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes en una distribución de datos fraccionados en entrenamiento y prueba. El cual consiste en calcular la media aritmética obtenida de las medidas de evaluación sobre diferentes particiones, este proceso se realiza un número de k veces. Esta técnica se utiliza en los procedimientos a partir de entrenamiento supervisado con el fin de estimar la precisión de un modelo que se llevará a cabo a la práctica [53]. Esta técnica es derivada del método Holdout el cual consiste en dividir un conjunto de datos que se relacionan como muestras, en dos nuevos subconjuntos denominados entrenamiento (training set) y prueba (test set), cuyo fin es de arrojar los datos de características aproximadas mediante una función de aproximación en relación al conjunto de entrenamiento, de allí genera la salida para la prueba analizada, esto solo en una sola iteración, como se indica en la figura 24.




Figura 24. Representación método de validación Holdout.

En la validación cruzada por número de iteraciones K-fold el conjunto de datos correspondientes a la muestra se dividen en K subconjuntos. Uno de los subconjuntos se utiliza como datos de prueba y el resto (K-1) como datos de entrenamiento. El proceso de validación cruzada es repetido durante k iteraciones, con cada uno de los posibles subconjuntos de datos de prueba. Finalmente se realiza la media aritmética de los resultados de cada iteración para obtener un único resultado. Lo más común es utilizar la validación cruzada de 10 iteraciones [54].

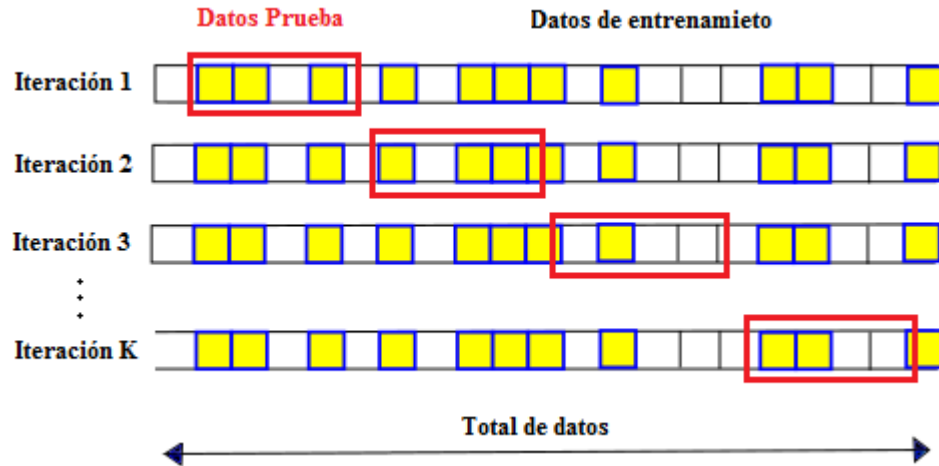


Figura 25. Representación método de validación K-Fold.

Para establecer el error de la validación, se tiene en cuenta el valor de la media aritmética para cada iteración de número k de iteraciones como se indica en la ecuación 1.

$$E = \frac{1}{K} \sum_{i=1}^K E_i \quad (1)$$

Utilizar el algoritmo de validación cruzada K-fold ofrece realizar una comparación entre los resultados de diferentes procedimientos en donde se utiliza una clasificación de forma predictiva por ejemplo, máquinas de vectores de soporte (SVM) y K-vecinos más cercanos (Knn), entre otros. Con esta validación, se puede verificar cuál de los métodos predictivos es más preciso, ya que se puede evaluar la tasa de error para cada uno de los métodos de predicción ejecutados.

Matriz de confusión: también conocida como matriz de error, es una tabla desarrollada para evaluar el rendimiento del modelo de un algoritmo de clasificación que realiza una predicción, esta matriz se compone de datos de prueba para los cuales se conocen su valor real. Como su nombre lo indica, esta es capaz de identificar la confusión que hay en el algoritmo de clasificación para la predicción de las clases en donde se puede ejecutar una etiquetación de clase errónea [55]. Esta matriz contiene los siguientes parámetros.

		Predicción	
		Positivos	Negativos
Observación	Positivos (P)	Verdaderos positivos (TP)	Falsos negativos (FN)
	Negativos (N)	Falsos positivos (FP)	Verdaderos negativos (TN)

Tabla 4. Estructura de una matriz de confusión.

- Positivo (P): la observación es positiva.
- Negativo (N): la observación no es positiva.
- Verdadero positivo (TP): la observación es positiva y se pronostica que será positiva.
- Falso negativo (FN): la observación es positiva, pero se pronostica negativa.
- Verdadero negativo (TN): la observación es negativa y se predice que es negativa.
- Falso positivo (FP): la observación es negativa, pero se pronostica positiva.

Estos parámetros se utilizan para calcular diferentes factores que evalúan el rendimiento del clasificador, algunos de estos factores son [8]:

Exactitud (Accuracy) ACC:

$$\frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

Sensibilidad (Sensitivity) TPR:

$$\frac{TP}{TP + FN} \quad (3)$$

Especificidad (Specificity) TNR:

$$\frac{TN}{TN + FP} \quad (4)$$

FalsePositiveRate FPR:

$$\frac{FP}{FP + TN} \quad (5)$$

FalseNegativeRate FNR:

$$\frac{FN}{FN + TP} \quad (6)$$

F1score:

$$\frac{2TP}{2TP + FP + FN} \quad (7)$$

Matthews Correlation Coefficient MCC:

$$\frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (8)$$

2.4.2 Análisis de componentes principales PCA y Kernel gaussiano.

El análisis de componentes principales es un algoritmo de reducción de dimensión desarrollado para reducir el número de variables en un conjunto de datos, almacenando la información relevante de los datos originales en un nuevo conjunto de variables denominadas componentes principales en relación con la dirección de la máxima varianza entre los datos analizados. Este algoritmo se utiliza para los métodos que se emplean en modelos predictivos [56]. Esta técnica se ejecuta mediante una transformación lineal que almacena los datos con mayor varianza en un eje que comprende un nuevo sistema de coordenadas, este eje se denomina primer componente principal, así mismo la segunda varianza máxima entre los datos se convierte en el siguiente eje o segunda componente principal, y así sucesivamente. Para construir esta transformación lineal debe construirse primero la matriz de covarianza o matriz de coeficientes de correlación. Existen dos métodos propuestos para el desarrollo de esta técnica de reducción, a partir de la matriz de covarianza y correlación [57].




Figura 26. Análisis de componentes principales (PCA).

Método basado en correlaciones: se considera una matriz de muestras de las aleatorias \mathbf{M} en un conjunto $\mathbf{F_j}$ para \mathbf{n} de sujetos

$$\mathbf{M_j} = \{\mathbf{F_j^B} \mid B = 1, \dots, n\} \quad (9)$$

Este método consiste en hallar un espacio menor al espacio original, en donde se proyecten los puntos sobre dicho subespacio y se conserve su información con el menor grado de distorsión posible. En primera instancia se realiza una primera aproximación sobre un subespacio de dimensión uno (una recta), en donde se posicionen en lo medido de lo posible las posiciones relativas iniciales, con el fin de que las distancias entre los puntos originales y las proyecciones sean las mínimas posibles, por lo tanto m_j en dirección $a_1 = (a_{11}, \dots, a_{1p})^T$. La proyección del punto m_j en dirección del escalar a_1 es:

$$r_j = a_1^T m_j^T \quad (10)$$

Ahora, d_j la distancia entre el punto m_j y la proyección con a_1 , enfatiza en:

$$\min \sum_{j=1}^B d_j^2 = \min \sum_{j=1}^B |m_j - r_j a_1^T|^2 \quad (11)$$

De forma análoga:

$$\max \sum_{j=1}^B r_j^2 = \max \sum_{j=1}^B a_1^T m_j^T m_j a_1 \quad (12)$$

Como las proyecciones de m_j pueden ser variables aleatorias con media cero, minimizar sus cuadrados equivale a maximizar sus varianzas, lo cual representa encontrar las direcciones de proyección.

Se tiene el vector de proyecciones:

$$r_1 = (r_1, r_2, \dots, r_n)^T = \mathbf{M}_{a1} \quad (13)$$

Se puede asociar como:

$$\max(r_1^T r_j) = \max(a_1^T \mathbf{M}^T \mathbf{M}_{a1}) \quad (14)$$

De igual forma la media de r_1 es nula, y su varianza es:

$$\frac{1}{n} r_1^T r_1 = \frac{1}{n} a_1^T \mathbf{M}^T \mathbf{M}_{a1} = a_1^T \mathbf{S} a_1 \quad (15)$$

Donde \mathbf{S} es la matriz de covarianza para observaciones o características. Ahora bien utilizando los multiplicadores de Lagrange $a_1^T a_1 = 1$, se tiene que:

$$R = a_1^T \mathbf{S} a_1 - \lambda(a_1^T a_1) \quad (16)$$

Derivando e igualando a cero:

$$\frac{\partial R}{\partial a_1} = 2\mathbf{S} a_1 - 2\lambda a_1 = 0 \quad (17)$$

En donde se tiene como resultado:

$$\mathbf{S} a_1 = \lambda a_1 \quad (18)$$

Esto significa que a_1 es un vector propio de la matriz \mathbf{S} asociado al valor propio λ , que corresponde a la varianza r_j . Por tanto, el vector propio asociado al mayor valor propio de \mathbf{S} corresponde al primer componente principal [58].

De igual forma este método presenta las siguientes propiedades [58]:

Conservan la variabilidad inicial, es decir, la suma de las varianzas de los componentes es igual a la suma de las varianzas de las variables originales, y la varianza generalizada de los componentes es igual a la original.

La proporción de variabilidad explicada por un componente es el cociente entre su varianza, el valor propio asociado al vector propio que lo define, y la suma de los valores propios de la matriz. Así, la proporción de variabilidad total explicada por el componente h es:

$$\frac{\lambda_h}{\sum_i \lambda_i} \quad (19)$$

Las covarianzas entre cada componente principal y las variables originales, vienen dadas por el producto de las coordenadas del vector propio que define el componente por su valor propio:

$$\text{cov}(r_i; m_1, \dots, m_p) = \lambda_i a_i \quad (20)$$

Los componentes principales proporcionan la predicción lineal óptima del conjunto de variables. La correlación entre un componente principal y una variable original es proporcional al coeficiente de esa variable en la definición del componente, y el coeficiente de proporcionalidad es el cociente entre la desviación típica del componente y la desviación típica de la variable. En síntesis el algoritmo propuesto para realizar una buena reducción mediante el análisis de componentes principales es:

Inicio

1. Obtener la matriz de datos M
2. Desarrollar la matriz de covarianza S .
3. Calcular los valores propios de la matriz S y sus vectores propios asociados.
4. Reorganizar de forma ascendente los vectores propios.
5. Proyectar los datos sobre las componentes o direcciones principales.

Fin

Kernel - análisis de componentes principales: Es una extensión del método de análisis de componentes principales PCA en donde se genera un nuevo espacio de dimensión superior donde las muestras están distribuidas en un mapeo no lineal. El Kernel de tipo gaussiano [59] indicado en la ecuación 14, es uno de los más utilizados para reducir la dimensionalidad no lineal.

$$K = \exp\left(-\frac{\|\tilde{\mathbf{M}} - \mathbf{M}\|^2}{2\sigma^2}\right) \quad (21)$$

Este presenta una dependencia por el factor σ que es definido para lograr una mejor agrupación de las muestras, en el nuevo espacio. De igual modo se realiza el mismo proceso que en PCA, pero con los datos proyectados al espacio del Kernel [60].

2.4.3 Algoritmo de clasificación K-nearest neighbors Knn.

Es un algoritmo de clasificación empleado en el campo de aprendizaje supervisado, posee una metodología no paramétrica y se utiliza esencialmente para la clasificación y regresión. Este algoritmo tiene como base un modelo de entrenamiento de k datos en un espacio de características [61]. Este algoritmo realiza la clasificación asignando la etiqueta que es más frecuente entre las k muestras de entrenamiento más cercanas a ese punto de consulta [62]. Este algoritmo consta de un parámetro k que es definido por el usuario, el cual se utiliza para establecer el número de vecinos que se relaciona con las muestras más cercanas a partir de ciertas características o similitudes y que están situados a una distancia en el espacio de trabajo.




Figura 27. Clasificador K-vecinos más cercanos Knn.

Este espacio se fracciona en regiones donde se sitúan las muestras etiquetadas del entrenamiento. En la clasificación de una muestra de prueba se establece a un tipo de clase o salida al algoritmo, siendo esta clase la más frecuente entre los k ejemplos más cercanos del entrenamiento en el espacio n -dimensional como lo indica la figura 27. El trayecto entre las muestras se puede establecer, entre ellas encontramos las distancias de tipo euclidiana, Mahalanobis, Chebyshev, entre otras, siendo la euclidiana las más utilizada [63]. Para este clasificador se tiene un conjunto de N datos a los cuales se relacionan n variables a predecir de un cierto número de características X donde la única salida es la clase C

$$X_1 C_1, \dots, X_N C_N \mid X_i = (X_{i,1}, \dots, X_{i,N}), C_i = (C^1, \dots, C^m), \quad i = 1, \dots, N \quad (22)$$

Establecidos los k vecinos se procede a buscar la distancia entre las muestras más cercanas D_x^k a la cual se le establecerá la clase más frecuente entre los k objetos a D_x^k . A continuación se propone la siguiente estructura para construir un algoritmo:

Inicio

Ingreso las muestras y características $\{X_1 C_1, \dots, X_N C_N\}$

Selecciono la muestra a clasificar $X = (x_1, \dots, x_n)$

Para cada muestra clasificada (X_i, C_i)

Calcular la distancia mínima $D_i = d(X_i, X)$

Asignar la clase C a partir de los k casos más frecuentes D_x^k

Fin

3 Desarrollo experimental

En este capítulo se expondrá los métodos empleados paso a paso para realizar la ejecución de este trabajo, se explicará la construcción del protocolo de caracterización de movimientos en una persona, además de la obtención de las características motoras en la ejecución de un movimiento. Por otro lado se expondrá las técnicas desarrolladas para realizar la clasificación y validación.

3.1 Caracterización del aspecto motor en el estándar UPDRS.

Como se referenció en la sección 2.1.5, el estándar propuesto para la evaluación y diagnóstico de la enfermedad de Parkinson UPDRS, realiza un análisis detallado en el aspecto cognitivo y motor del cuerpo. Debido a esto, se propone realizar un análisis detallado para la evaluación motora de una persona extrayendo 4 ejercicios característicos definidos en la sección 3 de este protocolo.

Los ejercicios que se relacionaron esta sección y en los cuales se abordará en secciones próximas son los siguientes:

- Movimientos rápidos alternantes de miembros superiores, en el estándar propuesto UPDRS se relaciona en la sección tres del aspecto motor y el ítem es el número 28.
- Agilidad con los miembros inferiores, en el estándar propuesto UPDRS se relaciona en la sección tres del aspecto motor y el ítem es el número 29.
- Levantarse de la silla, en el estándar propuesto UPDRS se relaciona en la sección tres del aspecto motor y el ítem es el número 30.
- Marcha, en el estándar propuesto UPDRS se relaciona en la sección tres del aspecto motor y el ítem es el número 32.

Este análisis se realizó a un número de 10 sujetos sin la patología de EP. Debido a esto se desarrolló una ficha técnica para cada sujeto, en donde se tiene en cuenta información con relación a las características anatómicas y con el consentimiento de cada sujeto.

3.1.1 Ficha técnica del sujeto de prueba.

Esta ficha se realiza con el fin de recopilar información sobre el sujeto de estudio. En ella se pueden encontrar un conjunto de características y cualidades anatómicas para cada sujeto. Análogamente se infiere en una información adicional correspondiente patologías o traumas padecidos por el sujeto y que pueden estar asociados a una afección del componente motor del cuerpo. Por último se le solicita al sujeto de estudio si está de acuerdo con la manipulación de los datos obtenidos para hacer un posterior análisis. En total se tiene la constancia de 10 fichas técnicas correspondiente a las 10 personas evaluadas, el formato de la base de datos se incluirá en la sección de anexos relacionado como ficha de prueba.

3.1.2 Caracterización del movimiento en la marcha.

El ítem 32 de la sección 3 del estándar UPDRS, se tiene como aspecto de análisis el movimiento realizado en la marcha. El análisis de la marcha se determina mediante un ciclo por fases del movimiento, debido a que es un modo de locomoción bípedo alternado en los miembros inferiores [64] en una postura correcta.

En el proceso de caracterización de las fases de movimiento en el ciclo de la marcha, se detallan 8 instantes de actividad que se distribuyen en 4 fases por movimiento del hemisferio derecho e izquierdo del cuerpo, teniendo en cuenta el movimiento en los brazos, la cadera y las piernas, estos se distribuyen en: contacto inicial, respuesta de carga, posición media, posición final, pre-balanceo, balanceo inicial, balanceo intermedio y balanceo final, como se indica en la figura 28.




Figura 28. Ciclo de la marcha y fases de movimiento.

En la figura 28 los segmentos etiquetado con el color rojo corresponden al hemisferio derecho del cuerpo, los segmentos asociados al color negro se asocian al hemisferio izquierdo.

3.1.3 Caracterización del movimiento sentado y de pie.

El ítem 30 del estándar UPDRS propone un ejercicio particular en el que se evalúa al sujeto en una actividad cotidiana como es el levantarse de un asiento de respaldo recto, con los brazos cruzados ante el pecho, teniendo en cuenta el comportamiento postural del cuerpo. Para este ejercicio se identificó y se propuso 3 fases o instantes de movimiento correspondientes a las posturas adoptadas por el sujeto en el momento de realizar la actividad. La fase o instante 1, hace referencia a la postura en que se encuentra el sujeto sentado en la silla, en seguida se propone la fase 2 como el momento en que el sujeto se levanta y deja el haciendo inclinando la postura del cuerpo, finalmente la fase o instante 3 hace referencia a la persona en una postura ideal que se encuentra de pie como lo indica la figura 29.




Figura 29. Caracterización de movimiento levantarse de un asiento.

3.1.4 Caracterización del movimiento en la alternación de las manos.

El ítem 28 del estándar, relaciona un movimiento de rápido ejecución y de alternación en los miembros superiores en donde se ejecuta la pronación y supinación en la mano de forma vertical, donde se evalúa la mayor amplitud posible. Este ejercicio se realiza en simultáneo con las dos manos y se ejecuta con la persona de pie. En esta actividad se proponen dos fases para la diferenciación del movimiento, la fase 1 correspondiente a la supinación vertical y la fase 2 ejecutando la pronación de la mano de forma vertical, estas se ilustran en la figura 30.




Figura 30. Caracterización de movimiento alternado de las manos.

3.1.5 Caracterización del movimiento de agilidad en los pies.

El ítem 29 acogido por el estándar, considera el movimiento en agilidad de los miembros inferiores del cuerpo para la cual se propone una caracterización en dos fases. La fase 1 corresponde a realizar un golpe con la parte final del pie en el suelo, y la fase 2 concierne en levantar el pie a una distancia del suelo, este movimiento se repite de la manera más rápida posible. La amplitud del movimiento debe ser alrededor de 7 a 10 cm como se representa en la figura 31, esta acción se ejecuta de forma alterna, se escoge un pie y seguido el otro para ejecutar el movimiento.




Figura 31. Caracterización de movimiento de agilidad en los pies.

3.2 Propiedades de conexión entre el dispositivo Microsoft Kinect y el entorno de programación Matlab.

El dispositivo Microsoft Kinect cuenta con 2 identificadores de imagen, uno es el sensor de color RGB y el otro es un sensor de profundidad mediante IR. Se puede habilitar para la identificación un método independiente, ya que se puede establecer en la caja de herramientas de adquisición de imágenes, cada sensor por separado. Esto significa que se debe crear un objeto de video por separado para cada uno de los dispositivos de color y profundidad (IR). En el sensor Kinect para Windows se muestra dos dispositivos separados en donde relaciona el ID para la imagen en RGB [1] y [2] la imagen de profundidad.

3.2.1 Imagen a color y en profundidad

La imagen a color se obtiene creando un objeto de video habilitando el identificador número 1 del dispositivo. De manera análoga para obtener la imagen en modo profundidad se crea un objeto pero se habilita el identificador número 2 del dispositivo. En la figura 32 se representa la visualización de la imagen en RGB y profundidad generada a partir de Microsoft Kinect.

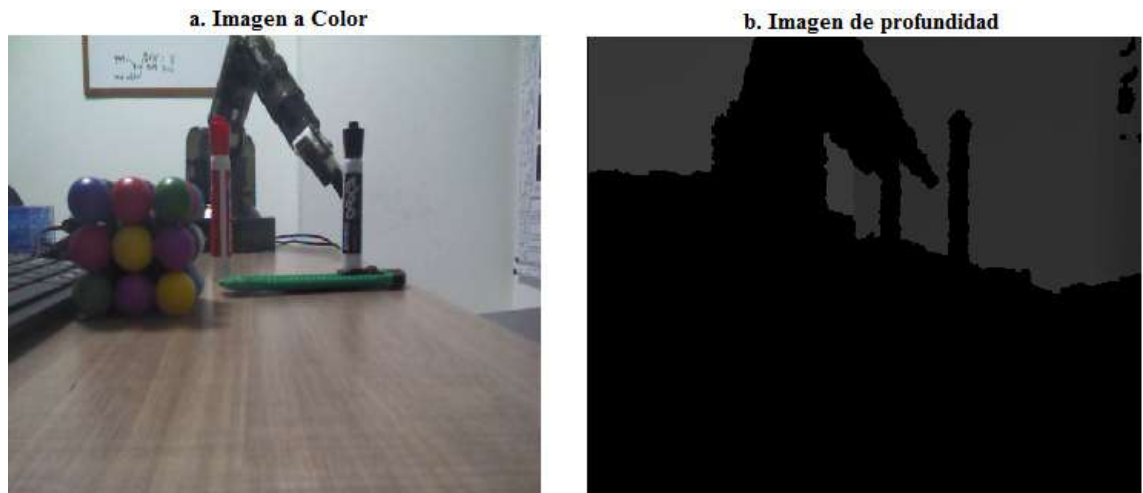


Figura 32. a. Imagen RGB, b. Imagen profundidad Microsoft Kinect.

3.2.2 Configuración manual del dispositivo Microsoft Kinect

Una vez se realiza el vínculo entre el sensor de imagen, el dispositivo cuenta con propiedades específicas de ajuste que se pueden manipular según la necesidad de la calidad de imagen o captura, ver tabla A1 en anexos. Para constituir el modo de adquisición de imagen con el dispositivo, se modificó la propiedad correspondiente al ángulo de elevación de la cámara, este se estableció en -10 grados con respecto al eje perpendicular del suelo (+Y). Se estableció a estos grados dado que el sensor se encontraba a una altura de 1.90 metros del suelo y la persona se posicionaba a 3 metros del dispositivo. Por otro lado, se dispuso del vector de aceleración de la gravedad para realizar los ajustes con respecto a la gravedad, esto se explicará detalladamente en sesiones posteriores. Finalmente, el número de cuadros adquiridos por segundo se instauró en 30 fps. Se realiza la aclaración de que estas características varían a medida que se ejecuta el dispositivo

3.2.3 Establecer el modo “TrackingMode”

Para aplicar el modo de seguimiento, es necesario operar con el sensor de profundidad IR, ya que gracias a este se puede ver en la configuración un conjunto de propiedades específicas asociadas al seguimiento y análisis cuantitativo de un esqueleto. Las propiedades para fijar el modo de seguimiento o rastreo se puede observar en la tabla A2 y en el código 1 capturaMovimientos en los anexos 2 y 4

3.3 Adquisición de datos mediante el dispositivo Microsoft Kinect

3.3.1 Acceso a datos esqueléticos.

La fuente seleccionada para realizar la captura de los datos es la fuente de profundidad, ya que esta es la encargada de proporcionar información sobre los datos esqueléticos con mejor precisión. En la configuración manual del disparador del sensor IR se selecciona un valor de trigger de 1 en repeticiones infinitas, este se establece para realizar adquisiciones de forma perdurable, con el fin de establecer un intervalo de adquisición se fija un parámetro o contador en donde se selecciona el número adquisiciones. Este parámetro de adquisición se estableció en $fnum = 100$ Frames o cuadros por ejecución.

Una vez se establece el número de cuadros que se adquieren por ejecución, se procede a iniciar la adquisición respecto a las variables que entregan la información de esqueleto ejecutado por Kinect. Este genera la información en forma de metadatos, los cuales son datos en matrices. El dispositivo Kinect puede rastrear la posición de hasta seis personas a la vista y puede ubicar activamente las articulaciones de dos de los seis esqueletos. Gracias a las modificaciones que permite realizar el dispositivo en las propiedades de uso, además se puede establecer el Kinect para una lectura en modo de pie, puesto que en este modo el dispositivo interpreta el número total de 20 articulaciones, de otro lado se puede establecer el modo sentado para leer solamente las articulaciones correspondientes los miembros superiores del cuerpo. Los campos generados en los metadatos que a su vez están relacionados con el seguimiento de los esqueletos se observan en la tabla A3 de anexos. Concluyendo, es posible observar mediante las propiedades del dispositivo las matrices de valores correspondientes a posición de las articulaciones en la imagen RGB y profundidad, además de los valores correspondientes a las coordenadas espaciales del sujeto en relación al

dispositivo, así como el número de esqueletos detectado por el dispositivo, el vector de gravedad para cada adquisición entre otros campos. Ver anexo 4 código 1 capturaMovimientos.

3.3.2 Visualización del esqueleto en la imagen de formato RGB

Para llevar a cabo la visualización del esqueleto en la imagen obtenida al realizar la adquisición, se construyó un algoritmo para la visualización del esqueleto paralelamente en la imagen en RGB. Este algoritmo se desarrolla a partir del número de esqueletos detectados, la imagen en RGB y los índices de las articulaciones generados por el sensor de profundidad. En primera medida se debe establecer en orden los índices para las articulaciones leídas por el dispositivo, posterior a ello se lee la imagen en RGB de cada fotograma adquirido, luego se genera un mapa esquelético para la conexión de las articulaciones y finalmente se dibuja en la imagen RGB el esqueleto del sujeto como se puede observar en la figura 33. Para solucionar cualquier duda ver el código 2 DibujarEsqueleto en el anexo.




Figura 33. Esqueleto en imagen RGB mediante Microsoft Kinect.

3.3.3 Obtención de coordenadas espaciales y corrección respecto a la gravedad

Una vez se establece la visualización del esqueleto en la imagen RGB, se procede a obtener la información correspondiente a las posiciones espaciales de las articulaciones en relación con el dispositivo mediante una de las propiedades de los metadatos. Posterior a ello se debe realizar un ajuste con base al sistema de referencia, ya que estas hacen parte de un marco de referencia entorno al sensor y pueden presentar variaciones según la posición inicial en que este se encuentre. De manera que se corrige el sistema de referencia con la ayuda del vector de gravedad calculado por el Kinect, con el fin de garantizar que los datos son tomados sobre una plataforma con pendiente cero estableciendo un marco de referencia global, Ver el código 3 CorregKinect en el anexo.

3.4 Extracción de características a partir de las coordenadas corregidas

Una vez establecido el marco de referencia global para el conjunto de coordenadas corregidas de las articulaciones, se procede a extraer la información que se puede utilizar como característica cuantitativa para el movimiento especificado a ejecutar por cada sujeto. Estas características varían según la posición de las articulaciones que adopte el sujeto en cada instante capturado en el fotograma. Por otra parte, fue necesario establecer tres ejes de orientación para cada articulación.

3.4.1 Ejes de orientación para cada articulación.

En principio se considera las coordenadas espaciales de una articulación como origen en el punto o , además de un vector \vec{A} que representa el segmento proximal y un vector \vec{B} , que representa el segmento distal. La unión de estos segmentos genera un plano que contiene las articulaciones o , a , b , como se indica en la figura 34. Cada articulación tendrá su propio sistema de referencia y las orientaciones de los tres ejes de este sistema dependen de la postura del cuerpo.




Figura 34. Definición de los ejes orientados para una articulación.

Se debe tener en cuenta que, para la generación de estos tres ejes orientados, se necesita tres articulaciones, la primera es la articulación a la que se le quiere definir estos ejes, esta sería la articulación de origen o , posterior a ello se tiene dos articulaciones que las cuales son adyacentes a la de origen, una se define como articulación distal b y proximal a . Así pues, se define el vector proximal \vec{A} como primer eje orientado, el segundo eje orientado \vec{C} es el resultante del producto cruz entre el vector distal y proximal, siendo este perpendicular al plano formado por las articulaciones, y por último el tercer eje de orientación \vec{D} se obtiene a partir del producto cruz entre el vector proximal y el vector perpendicular al plano de las articulaciones, estos se relacionan en la figura 34. Se debe tener en cuenta que para cada articulación se obtienen tres ejes de orientación, es importante definir en este punto que el número de articulaciones a las cuales a manipular son 15 como se indica en la tabla 5 y en la figura 35, ya que para la generación de estos ejes se necesitan una articulación distal y proximal, para las articulaciones que se encuentran en las extremidades del cuerpo no se puede generar estos tres ejes. Las articulaciones reconocidas por Kinect para las extremidades del cuerpo no se pueden generar estos tres ejes.

Articulaciones a manipular			
Número	Articulación	Número	Articulación
1	Centro de cadera	9	Muñeca derecha
2	Torso	10	Cadera izquierda
3	Hombro central	11	Rodilla izquierda
4	Hombro izquierdo	12	Tobillo izquierdo
5	Codo izquierdo	13	Cadera derecha
6	Muñeca izquierda	14	Rodilla derecha
7	Hombro derecho	15	Tobillo derecho
8	Codo derecho		

Tabla 5. Articulaciones a manipular

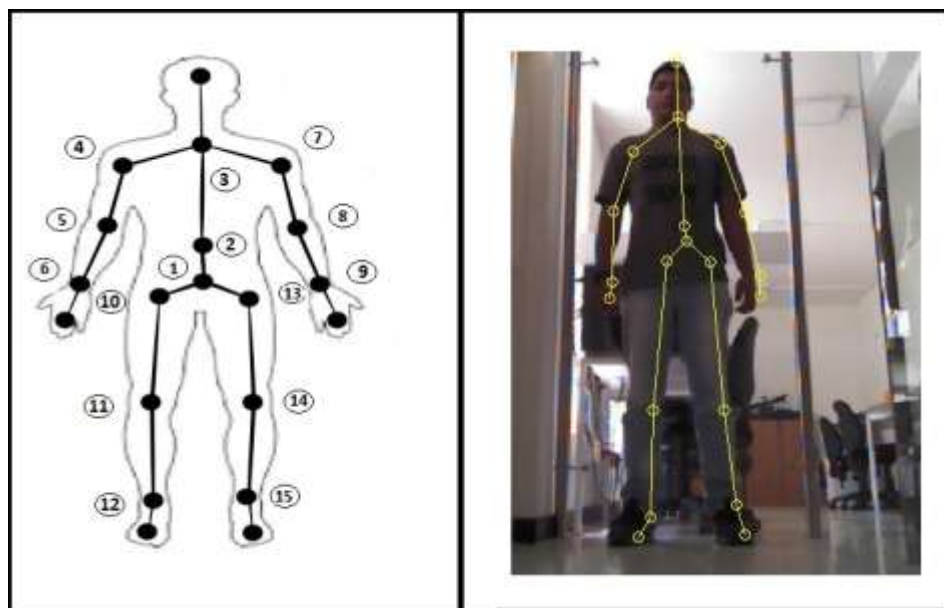


Figura 35. Articulaciones a manipular.

Una de las características es el desplazamiento angular entre los ejes de orientación con respecto a los ejes de la articulación del centro de cadera, la idea es identificar la variación en los ángulos para cada uno de los ejes desarrollados para cada articulación como se indica en la figura 36. La manera de obtener los ángulos entre los ejes de orientación se explica con la ecuación en la sección posterior mediante la ecuación 23. Ver el código 1 y 4 en anexos.




Figura 36. Ángulo entre ejes de orientación.

3.4.2 Ángulo entre segmentos.

Esta característica se construye a partir de la información en la figura 34, en donde se recurre al vector proximal \vec{A} y distal \vec{B} para cada articulación, matemáticamente se puede conocer que el ángulo generado a partir de dos vectores se define como:

$$\theta = \cos^{-1} \left(\frac{\vec{A} \cdot \vec{B}}{\|\vec{A}\| \cdot \|\vec{B}\|} \right) \quad (23)$$

Donde:

$\vec{A} \cdot \vec{B}$ Es el producto escalar entre los vectores correspondientes a la articulación distal y proximal.

$\|\vec{A}\| \cdot \|\vec{B}\|$ Es el producto de los módulos correspondiente a los vectores proximales y distales.

De esta forma se puede obtener el ángulo entre dos segmentos cuyo origen en común es cada articulación en relación a las articulaciones proximales y distales, ver figura 34. Ver en anexo el código 1 y 5.

3.4.3 Distancia de las articulaciones respecto al centro de cadera.

Se define el punto central para cada sujeto como la articulación centro de cadera, y se halla la distancia que hay entre cada una de las articulaciones en relación a esta, para ello se utiliza el centro de cadera como la posición de origen con respecto a las demás articulaciones, mediante la ecuación

$$d_{ac} = \sqrt{(x_o - x_i)^2 + (y_o - y_i)^2 + (z_o - z_i)^2} \quad (24)$$

Donde x_o, y_o, z_o corresponden al punto de coordenadas corregidas para la articulación del centro de cadera, y x_i, y_i, z_i corresponde a las coordenadas corregidas par cada articulación. Esta distancia se relaciona como trayecto entre cada articulación con respecto al centro de cadera como se observa en la figura 36. Ver en anexos 4 y 9 el código 1 y 6.




Figura 37. Distancia de cada articulación a centro de cadera.

3.4.4 Definición del centro de gravedad y distancia con respecto a este.

El centro de gravedad para una persona se genera en la zona pélvica del cuerpo. Sin embargo, para algunas posturas este puede encontrarse en el exterior del cuerpo, por esto se propone que esta característica se pueda calcular de manera similar a la descrita en el numeral 3.4.3, con la diferencia que el centro de gravedad es entregado como un vector de tres coordenadas \overrightarrow{VG} por el dispositivo Kinect. En relación a este se calcula la distancia d_{cc} entre el centro de gravedad con respecto a cada articulación con la ayuda de la ecuación 24.

Donde x_{oc}, y_{oc}, z_{oc} corresponden al punto de coordenadas devueltas por el dispositivo para el centro de gravedad, y x_i, y_i, z_i son las coordenadas de las articulaciones, como se indica en la figura 38. Ver el código 1 en el anexo.




Figura 38. Distancia de cada articulación a centro de gravedad.

3.4.5 Velocidad angular para cada articulación.

Finalmente se genera la característica de velocidad angular para las articulaciones ya que es una forma de medida de rapidez de rotación en la cinemática de un punto en particular, cuyo fin es el de conocer el ángulo girado por unidad de tiempo. Para ello se recurre al ángulo de cada articulación visto en la sección 3.4.2 y además se extrae el tiempo de cada adquisición generado, para así obtener:

$$\omega = \frac{\Delta\theta}{\Delta t} \quad (25)$$

Donde $\Delta\theta$ y Δt es la diferencia entre ángulos y tiempos de los cuadros de adquisición, como se indica en la ecuación 26.

$$\Delta f_{num} = f_{num+1} - f_{num} \quad (26)$$

3.4.6 Definición de variables y metodología de adquisición de datos.

Una vez se tiene descritas las características para las articulaciones por muestras adquiridas se procede a realizar el procedimiento de obtención de las variables, estas se representan de la siguiente manera que \mathbf{M} es la matriz con las muestras adquiridas, J es el número de articulaciones, B es el número de características por articulación, además N es el número de muestras por adquisición, como se indica en la ecuación 27.

$$\mathbf{M} = \{\mathbf{m}_i^{(h)} \in \mathbf{R}^B \mid 1 < i < J\}_{h=1}^N \quad (27)$$

A cada muestra adquirida, se asocia con una etiqueta como se muestra en la ecuación 28.

$$\mathbf{L} = \{\mathbf{l}_i^{(h)} \mid 1 < i < J\}_{h=1}^N \quad (28)$$

De igual manera se estableció un proceso estándar para la adquisición de datos. Este consistió en posicionar el Kinect a una altura de 1.90 m con respecto al suelo y a una distancia de dos metros con relación al sujeto de estudio. De igual forma, se estableció que el ángulo de apertura del dispositivo Microsoft Kinect fue de -10 grados, como se indica en la figura 39.




Figura 39. Protocolo de adquisición.

Al momento de realizar la captura, se puntualizó en las diferentes fases descritas para cada movimiento realizado por el sujeto de estudio, esto con el fin de no generar alguna confusión y posterior error a la hora de realizar la captura de datos. En esta adquisición se capturan 100 muestras por fase del movimiento descrito, de manera que para el mismo sujeto se adquiere un total de datos correspondiente al producto de la fases que contiene el movimiento por el número de adquisiciones, $N \times 100$ muestras, cada una con las características descritas. Se dispuso de 10 sujetos de estudio distribuidos de la siguiente forma: 6 hombres y 4 mujeres, en la cual se registraron diferentes características para cada sujeto en una base de datos, siendo esta de carácter académico y con la disposición de cada uno de los sujetos analizados.

3.5 Implementación de algoritmos de validación, de reducción de dimensión y clasificación para las muestras adquiridas.

Se realizó la validación de las muestras adquiridas mediante el algoritmo K-Fold Cross-Validation, el cual agrupa un conjunto de datos aleatorios como entrenamiento y el restante de datos como prueba, además de un número de folds $k=10$, el cual registra 10 veces el error para la predicción de la clasificación. Este método se empleó a las tres metodologías utilizadas con el fin de obtener una buena clasificación de datos a partir de un valor a predecir (Knn clasification, PCA con Knn clasification y Kernel PCA con Knn clasification), todo esto con el fin de encontrar el método más efectivo para realizar el proceso de clasificación.

De igual forma, se realiza la validación generando una matriz de confusión para las muestras analizadas, la cual visualiza el desempeño del código implementado de aprendizaje supervisado. Obteniendo parámetros de exactitud, error, sensibilidad especificidad, False Positive Rate, F1_Score, MatthewsCorrelationCoefficient, Kappa.

3.5.1 Matriz de confusión para el algoritmo de clasificación Knn

A partir de la base de datos con las muestras adquiridas, se realiza la etiquetación por fase del movimiento realizado, se calcula la matriz de confusión para el algoritmo de clasificación Knn ya que este es un método de categorización supervisado el cual estima en un conjunto de datos un set de entrenamiento con relación a prototipos de prueba. En este se relacionan las muestras con características similares a partir de un número de vecinos más cercanos en relación a la muestra identificada como prueba para realizar la clasificación a una distancia determinada. De igual forma se ejecuta la validación para cada número de vecino establecido, ver los anexos 10 y 11 los cuales hacen referencia a los códigos 7 y 8.

3.5.2 Matriz de confusión para el algoritmo de reducción PCA y clasificación Knn.

Para el algoritmo de reducción mediante PCA y de clasificación Knn, se varían los parámetros correspondientes a los vectores propios y de k número vecinos más cercanos, a este proceso se realiza la validación con el algoritmo de matriz de confusión como se puede ver en el anexo del código 7 y 8. Todo esto con el fin de observar el mejor comportamiento de las muestras en el nuevo espacio de trabajo a partir de las componentes principales asociadas a los vectores propios, y a la clasificación generada a partir del número de vecinos más cercanos.

3.5.3 Matriz de confusión para el algoritmo de reducción PCA con un Kernel gaussiano,

Este algoritmo se implementa de igual forma como en las secciones 3.5.1 y 3.5.2, con la única diferencia que el Kernel tiene una representación de tipo gaussiano y en su estructura contiene un parámetro σ el cual a medida que aumenta su valor, disminuye significativamente la amplitud conservando el área de interés. Los parámetros que se modifican son el número de vectores propios, el número de vecinos y el parámetro σ . Ver anexo código 7 y 8.

3.6 Esquema por bloques de la ejecución del desarrollo experimental

Para obtener claridad con el proceso de ejecución de este trabajo, se realiza el diagrama de bloques que se ilustra en la figura 40 en donde se da seguimiento a las etapas ejecutadas.

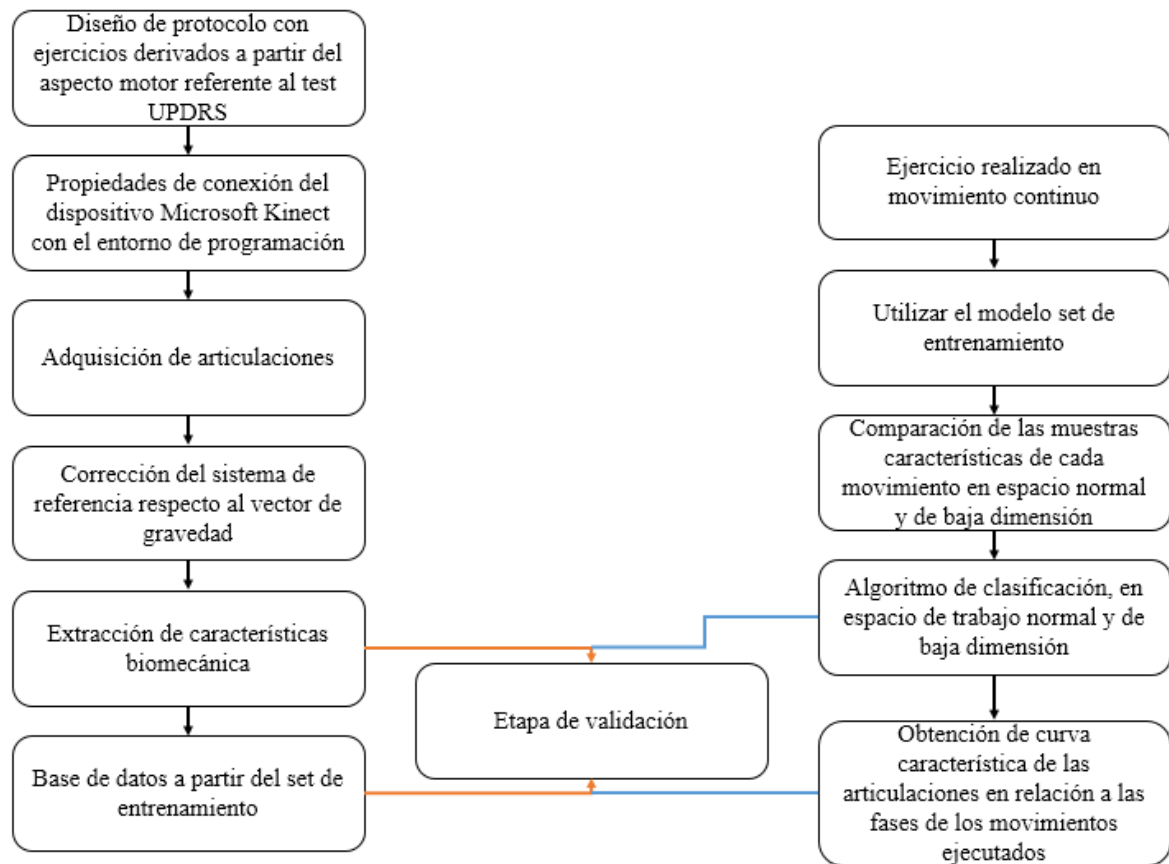


Figura 40. Etapas de desarrollo experimental.

4 Resultados y discusión.

En esta sección se desarrollarán dos etapas. La primera etapa corresponde a los algoritmos empleados para la validación de muestras a manipular, en donde se modifican diferentes parámetros que son selectivos en sus estructuras, con el fin de conseguir el método más eficaz y de mejor rendimiento para realizar la posterior clasificación. En la segunda etapa, se expondrá los resultados desarrollados a partir del algoritmo de clasificación por fase de movimiento, en donde se resaltará los detalles encontrados en relación al estado del arte.

Resultados de validación de las muestras adquiridas: Esta validación se efectuó para conocer el comportamiento en específico de los algoritmos de reducción de dimensión y de clasificación, en donde se varió el número de vecinos asociados al clasificador encontrando que con cinco vecinos este algoritmo reflejó el mejor comportamiento como se observa en las tabla 6, 7, 8, 9, 10. Los datos correspondientes a las variaciones del número de vecinos se pueden ver en el anexo 14, 15, 16, 17, 18.

Por otra parte para cada movimiento analizado se asocia la curva de tasa de reconocimiento cuyo fin es el de observar el comportamiento de la exactitud entre el conjunto de muestras a analizar según el espacio de baja dimensión, este se emplea para determinar la dimensión a la cual el algoritmo presenta una exactitud mayor para poder así determinar la predicción más distinguible a la hora de realizar la clasificación.

Movimiento de Marcha					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9935 \pm 0.0029	0.0056 \pm 0.0021	0.9943 \pm 0.0020	0.9992 \pm 0.0003	0.9943 \pm 0.0020	0.0008 \pm 0.0003
PCA – Knn, k = 5					
0.9942 \pm 0.0036	0.0057 \pm 0.0036	0.9944 \pm 0.0035	0.9992 \pm 0.0005	0.9942 \pm 0.0035	0.0008 \pm 0.0005
KPCA – Knn, k = 5					
0.9860 \pm 0.0054	0.0054 \pm 0.0140	0.9862 \pm 0.0053	0.9980 \pm 0.0008	0.9860 \pm 0.0052	0.0020 \pm 0.0008

Tabla 6. Resultados de validación de las muestras adquiridas para la marcha.

En el ejercicio de la marcha a pesar de estar constituido por 8 etapas de movimiento, se observó una buena agrupación por parte de las muestras para cada fase ejecutada, este proceso de validación se generó al modelo predictivo de cada fase.




Figura 41. Tasa de reconocimiento para las muestras adquiridas en la marcha.

El comportamiento más exacto se presentó en el algoritmo Knn, además de los algoritmos donde se estableció un espacio característico de más baja dimensión, el número de componentes principales para la reorganización de las muestras en el espacio de trabajo en cada método se estabilizó a partir de un numero de 30 componentes principales para cada método PCA y PCA con el Kernel gaussiano como se muestra en la figura 42 y 43 respectivamente. La tasa de reconocimiento en porcentaje en relación a la baja dimensión se observa en la figura 41. Se puede observar que la agrupación de los datos tanto en alta como en baja dimensión, (ver figura 42 y 43) reflejan grupos de muestras traslapados unos con otros, estos asocian las fases del movimiento en que se encuentra una persona indicando que cada etapa puede ser semejante a otra, pese a esto se puede identificar regiones que asocian y diferencian una fase de otra. En el espacio de baja dimensión se busca una mejor agrupación reduciendo la distancia entre muestras a partir de la máxima varianza entre ellas, para visualizar mejor la región por fase de movimiento.




Figura 42. Agrupación de muestras referente a la marcha con PCA.




Figura 43. Agrupación de muestras referente a la marcha con KPCA.

Movimiento sentado de pie					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9981	0.0023	0.9977	0.9988	0.9977	0.0012
± 0.0029	± 0.0042	± 0.0040	± 0.0020	± 0.0044	± 0.0020
PCA – Knn, k = 5					
0.9987	0.0013	0.9987	0.9993	0.9986	0.0007
± 0.0017	± 0.0017	± 0.0017	± 0.0008	± 0.0018	± 0.0008
KPCA – Knn, k = 5					
0.9967	0.0033	0.9966	0.9983	0.9967	0.0017
± 0.0027	± 0.0027	± 0.0028	± 0.0014	± 0.0027	± 0.0014

Tabla 7. Resultados de validación de las muestras adquiridas en el ejercicio sentado de pie

Como este movimiento se diferenció en tres etapas distinguibles, las muestras adquiridas se agruparon de muy buena manera en los diferentes espacios de trabajo, la variación en el número de vecinos en el algoritmo reflejó que para cinco vecinos el comportamiento de este fue más exacto y hubo una menor desviación entre las muestras como se indica en la tabla 7. En el anexo 15 se observa cómo se comportó el algoritmo a partir de la variación del número de vecinos. La tasa de reconocimiento se muestra para el ejercicio sentado de pie se muestra en la figura 44. La organización de las muestras en los espacios de trabajo de baja dimensión se muestra en las figuras 45 y 46.




Figura 44. Tasa de reconocimiento ejercicio sentado de pie.




Figura 45. Agrupación de muestras referente al ejercicio sentado de pie con PCA.

En este movimiento se distinguió de buena marea en las tres fases del movimiento, de igual modo se encontró que la reorganización de las muestras en el espacio de baja dimensión caracterizó mejor por regiones las fases.




Figura 46. Agrupación de muestras referente al ejercicio sentado de pie con KPCA.

Movimiento alternación manos					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9910	0.0075	0.9903	0.9949	0.9951	0.0051
± 0.0060	± 0.0049	± 0.0079	± 0.0071	± 0.0070	± 0.0071
PCA – Knn, k = 5					
0.9930	0.0070	0.9911	0.9947	0.9953	0.0053
± 0.0071	± 0.0071	± 0.0109	± 0.0105	± 0.0089	± 0.0105
KPCA – Knn, k = 5					
0.9740	0.0260	0.9730	0.9755	0.9744	0.0245
± 0.0084	± 0.0084	± 0.0095	± 0.0120	± 0.0136	± 0.0120

Tabla 8. Resultados de validación de las muestras adquiridas en el ejercicio alternación manos.

Para el ejercicio de la alternación de las manos, pese a una exactitud entre las muestras aceptable para las tres metodologías, se debe tener en cuenta que las dos fases desarrolladas son de carácter similar, ya que cada fase se diferenció en el estado final referente a la pronación y supinación de la mano, estos movimientos se desarrollan en un rango de 0 a 180 grados con relación al eje de rotación de la articulación proximal a la mano. Gracias a la variación de parámetros en el algoritmo PCA se observó el comportamiento más exacto, además en la figura 47 se observa el desempeño de reconocimiento en relación al algoritmo KPCA. La agrupación de las muestras se en los espacios de baja dimensión se relacionan en la figuras 48 y 49 respectivamente para el método PCA y KPCA.




Figura 47. Tasa de reconocimiento ejercicio alternación manos.




Figura 48. Agrupación de muestras referente al ejercicio alternación de manos con PCA.

Pese a que este movimiento se diferenció en dos fases, las muestras presentaron una superposición en el espacio característico y se reflejó que la distancia entre las regiones en donde se posicionaban las muestras en relación a las fases, puede inferir para que el algoritmo de clasificación presente un error en la predicción. En el anexo 16 se puede observar cómo se comportó las muestras en relación a la variación del número de vecinos en el algoritmo de clasificación.




Figura 49. Agrupación de muestras referente al ejercicio alternación de manos con KPCA.

A continuación se presenta los resultados obtenidos para el ejercicio de agilidad en el pie derecho e izquierdo, este movimiento al igual que el anterior se diferenció en dos etapas, las cuales presentaron características muy similares por la ejecución del movimiento y generaron una agrupación un poco insegura ya que las muestras distinguidas en dos regiones están superpuestas en un mismo espacio. De igual forma se presenta en la tabla 9 y 10 el comportamiento más exacto del algoritmo de clasificación a partir del número de vecinos modificados.

Movimiento agilidad pie derecho					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9767 \pm 0.0085	0.0265 \pm 0.0094	0.9721 \pm 0.0131	0.9748 \pm 0.0085	0.9749 \pm 0.0090	0.0252 \pm 0.0085
PCA – Knn, k = 5					
0.9750 \pm 0.0137	0.0250 \pm 0.0137	0.9733 \pm 0.0191	0.9774 \pm 0.0145	0.9763 \pm 0.0156	0.0226 \pm 0.0145
KPCA – Knn, k = 5					
0.9610 \pm 0.0145	0.0390 \pm 0.0145	0.9640 \pm 0.0253	0.9640 \pm 0.0253	0.9582 \pm 0.0188	0.0442 \pm 0.0232

Tabla 9. Resultados de validación de las muestras adquiridas en el ejercicio agilidad pie derecho.




Figura 50. Tasa de reconocimiento ejercicio agilidad pie derecho.




Figura 51. Agrupación de muestras referente al ejercicio pie derecho con PCA.




Figura 52. Agrupación de muestras referente al ejercicio pie derecho con KPCA.

Movimiento agilidad pie izquierdo					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9795 \pm 0.0078	0.0225 \pm 0.0079	0.9720 \pm 0.0104	0.9830 \pm 0.0103	0.9828 \pm 0.0110	0.0170 \pm 0.0103
PCA – Knn, k = 5					
0.9770 \pm 0.0086	0.0230 \pm 0.0086	0.9748 \pm 0.0121	0.9791 \pm 0.0134	0.9789 \pm 0.0138	0.0209 \pm 0.0134
KPCA – Knn, k = 5					
0.9640 \pm 0.0115	0.0360 \pm 0.0115	0.9532 \pm 0.0259	0.9739 \pm 0.0086	0.9735 \pm 0.0082	0.0261 \pm 0.0086

Tabla 10. Resultados de validación de las muestras adquiridas en el ejercicio agilidad pie izquierdo.




Figura 53. Tasa de reconocimiento ejercicio agilidad pie izquierdo.




Figura 54. Agrupación de muestras referente al ejercicio pie izquierdo con PCA.




Figura 55. Agrupación de muestras referente al ejercicio pie izquierdo con KPCA.

Al igual que en el ejercicio de alternación de las manos, cuando los ejercicios se caracterizaron en dos se representó confusiones a la hora de discriminar la fase en que se encuentra el movimiento, por ende la exactitud entre los métodos no es tan alta, a pesar de la variación de los parámetros de los algoritmos. Como se mencionó anteriormente en la figura 50 y 53 se puede ver el comportamiento en la tasa de reconocimiento para el pie derecho e izquierdo respectivamente según el espacio de baja dimensión empleado para cada metodología como lo representa las figuras 51, 52 y 54, 55 respectivamente. Se observó el comportamiento de las tres metodologías y a pesar de que el porcentaje de exactitud en las tres técnicas es alto en todos los ejercicios realizados, la reorganización de las muestras generada a partir del Kernel gaussiano no fue mayor a las variaciones de cada componente principal lineal. Con base a lo anterior se toma la decisión de utilizar la clasificación de las muestras a partir del algoritmo de clasificación knn y PCA con knn.

Resultados de clasificación: para este trabajo se quiere comprobar que el dispositivo Microsoft Kinect es capaz de registrar y reconocer las curvas características de las articulaciones en relación a un movimiento ejecutado con un nivel de detalle optimo y aceptable en comparación de un equipo de captura a nivel profesional. Por otra parte, se quiere elaborar una herramienta de análisis que le permita a un especialista evaluar el estado en que se encuentra el aspecto motor de un paciente realizando la comparación en las curvas características obtenidas para cada articulación según el movimiento ejecutado (marcha, sentado de pie o levantarse de una silla, alternación de manos y agilidad en los pies) por la persona con la respectiva fase en la que se desarrolló.

A continuación se presentan los resultados obtenidos relacionados a la clasificación por fase de movimiento de las muestras correspondientes a un sujeto de prueba. En el ciclo de la marcha, se obtuvo un resultado acorde al estado del arte como se indica en la figura 56, ya que la variación en el centro de cadera para una persona decrece a medida que la persona ejecuta la marcha, este análisis se desarrolló para 4 sujetos de prueba.




Figura 56. Variación angular de la cadera en la marcha [65]

A pesar de que se obtiene una señal con ruido, el dispositivo es capaz de captar el decrecimiento angular para la articulación de centro de cadera. En el estado del arte esta variación es mucho más pronunciada ya que el ángulo varía entre -5 a 40 grados en promedio para un paciente normal [65], en nuestro estudio la variación angular se obtuvo en un rango de 20 a 40 grados. En el proceso de clasificación, se pudo apreciar un buen comportamiento de las muestras de los sujetos de prueba, ya que es distinguible la etapa del movimiento en que se encuentra la persona según la fase. En la figura 57, 58, 59, 60 se relaciona los cuatro sujetos de estudio y se estima la fase del movimiento de la marcha en que se encuentra la persona en relación a una escala de color con respecto a la curva característica del centro de cadera, cabe mencionar que la curva distintiva de cada persona para esta articulación varía en relación a la velocidad de ejecución del movimiento, aun así se logra interpretar la fase en que este se encuentra. De igual forma, el procedimiento de clasificación aun no desarrolla una clasificación totalmente óptima ya que como se puede observar en la figura 59 en el sujeto 3, estima dos intervalos de clasificación correspondiente a la fase 7, en la cual no se debería manifestar ya que solamente se genera un ciclo de marcha.




Figura 57. Ángulo en la cadera para el movimiento de marcha sujeto 1.




Figura 58. Ángulo en la cadera para el movimiento de marcha sujeto 2.




Figura 59. Ángulo en la cadera para el movimiento de marcha sujeto 3.



Figura 60. Ángulo en la cadera para el movimiento de marcha sujeto 4.

Por otro lado, se analizó el comportamiento de la velocidad angular en la rodilla izquierda de una persona en el movimiento de la marcha, ya que en el estado del arte se asocia una curva característica como se indica en la figura 61 para una rodilla derecha. Debido a que se analizó la curva correspondiente a la rodilla izquierda, esta se visualiza primero en extensión y luego flexión, es por eso que la gráfica 61 es el espejo ya que se realiza con la pierna derecha donde primero se realiza la flexión y posterior a ello la extensión. Cabe mencionar que el tiempo de muestreo de las muestras adquiridas fue relativamente grande en centisegundos, el comportamiento de la velocidad angular no se dio a gran escala, aun así se manifestó los picos característicos observados en el estado del arte como se muestra en la figura 62.




Figura 61. Velocidad angular en la rodilla para pacientes sanos y con afecciones [66].

A la hora de clasificar la fase del movimiento, este registró que a medida que se da inicio y se avanza en la actividad, la variación de velocidad angular en la rodilla aumenta y se evidencia el cambio correspondiente a la rapidez de la flexión y extensión de esta articulación según la fase en que se encuentre el movimiento.

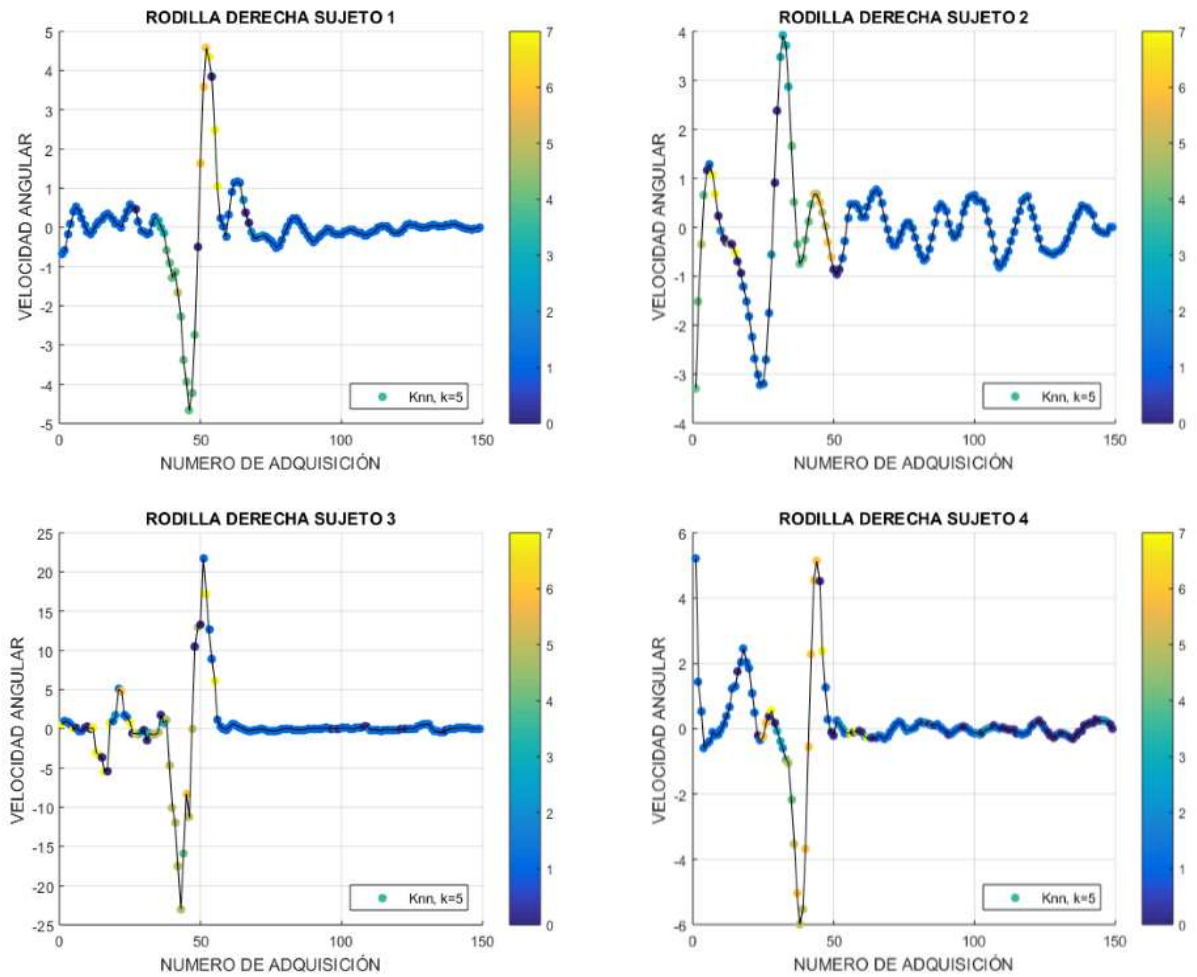


Figura 62. Velocidad angular de la rodilla izquierda en la marcha.

Para el movimiento sentado de pie, se realizó el análisis a la tendencia de crecimiento y decrecimiento de la velocidad angular correspondiente a la articulación del centro de cadera, ya que en la literatura se encuentra la curva característica del movimiento levantarse y sentarse de una silla como se indica en la figura 63, En esta figura se representa en la fase I y fase II la curva generada al levantarse de una silla, el cual es el movimiento dispuesto a realizar en este trabajo.




Figura 63. Curva característica del centro de cadera en el movimiento sentarse y levantarse de una silla [67].

El comportamiento obtenido fue muy similar a la fase I y II de la figura 63 antes mencionadas para el centro de cadera, recordando que este ejercicio se dividió en tres fases, a la hora de realizar la clasificación por etapa del movimiento, se pudo distinguir la fase que se desarrolló el ejercicio como se indica en las figuras 64, 65, 66, 67.




Figura 64. Clasificación por fase del movimiento sentado de pie sujeto 1.




Figura 65. Clasificación por fase del movimiento sentado de pie sujeto 2.




Figura 66. Clasificación por fase del movimiento sentado de pie sujeto 3.

Al momento de levantarse de la silla, la articulación del centro de cadera inicia el desplazamiento aumentando la velocidad en la articulación, esto hasta completar la ejecución del movimiento y quedar de pie, en ese instante se alcanza el pico máximo en la gráfica y la velocidad de la articulación empieza a disminuir ya que en la fase de pie no se produce desplazamiento por parte de esta articulación y de esta forma la velocidad angular a medida que se adquiere las muestras empieza a disminuir.




Figura 67. Clasificación por fase del movimiento sentado de pie sujeto 4.

El comportamiento de identificación de fase de movimiento fue muy satisfactorio ya que por cada fase discriminada, se reflejó un buen reconocimiento de las muestras para una posterior a ello realizar la clasificación. Los resultados obtenidos para el movimiento de alternación de las manos en la pronación y supinación de las manos, se obtuvo un buen comportamiento por parte de las muestras adquiridas, ya que en la literatura se encuentra la curva característica en relación a la velocidad angular de la muñeca como se ilustra en la figura 68.




Figura 68. Curva característica en la pronación y supinación de las manos [68].

El comportamiento observado para los sujetos de estudio en un solo giro de la mano en donde se inicia en la pronación y posterior a ello se realiza la supinación presenta una variación con respecto a la rapidez angular de giro, de igual modo en cada giro generado se puede establecer el movimiento de pronación y de supinación como se indica en las figuras 69, 70, 71.

Aunque la señal detectada presenta mucho ruido, se puede establecer la tendencia al momento de realizar el giro de la mano. En el momento de realizar la clasificación se puede observar que reconoce las dos fases en que se categorizo este movimiento, sin embargo esta clasificación no es del todo acertado, ya que estas fases se caracterización la posición final de las manos y no en el giro de esta, por tal motivo se presentan confusiones a la hora de clasificar la muestra de prueba.

Se hizo la prueba de realizar este movimiento en repetidas ocasiones con el fin de observar la rapidez angular de la muñeca en relación a las dos fases, en donde los resultados obtenidos visualizan características similares a la curva vista en el estado del arte, en la figura 72 se puede ver las dos fases discriminadas por color.




Figura 69. Clasificación del movimiento generado a partir de la alternación de las manos sujeto 1.




Figura 70. Clasificación del movimiento generado a partir de la alternación de las manos sujeto 2.




Figura 71. Clasificación del movimiento generado a partir de la alternación de las manos sujeto 3.

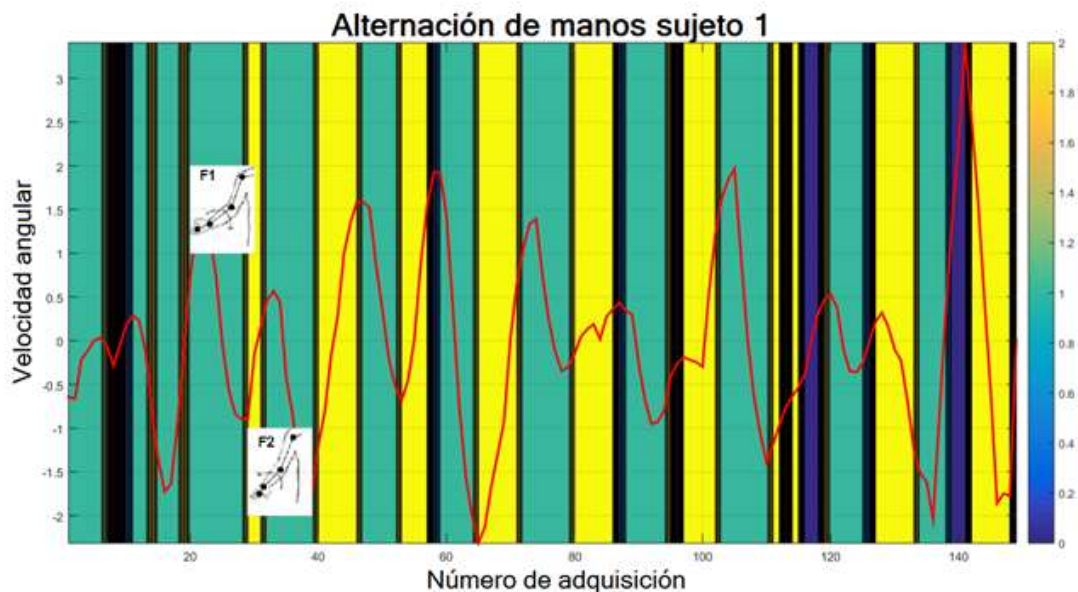


Figura 72. Clasificación por fase de movimiento en la alternación de las manos.

Se puede observar en las figuras 69, 70, 71 que las fases detectadas como pronación de las manos se visualizó de color verde presenta una curva característica con un decaimiento en el movimiento angular, por otro lado la fase correspondiente a la supinación de la muñeca presenta un crecimiento en la rapidez angular, esta se identifica de color amarillo. Para el movimiento de prueba visualizado en la figura 72 se realizó 8 giros en la muñeca y se lograron detectar 10 giros en la mano, teniendo en cuenta lo mencionado anteriormente en el número de adquisición 110 y 115, se presentaron dos confusiones que sistema lo clasificó como fase de supinación.

Para el movimiento de agilidad en el pie tanto en el derecho como en el izquierdo, no se entraron registros en el estado del arte, por eso se tomó como iniciativa cuantificar el ángulo que realiza la rodilla elevar la pierna y bajar la misma, el resultado obtenido para la pierna derecha se observa en la figura 73, en esta se puede ver una tendencia en la curva

característica que a medida que se baja la pierna, el ángulo en la rodilla aumenta, de igual manera cuando se eleva la pierna este disminuye.

Por otra parte se visualiza una clasificación no muy acertada ya que como se observa en la figura 73 en el sujeto 1 generó una sola fase de movimiento correspondiente a tener el pie en el suelo, de igual manera en el sujeto 3 generó una clasificación correspondiente a la fase de elevación del pie, y en el sujeto 2 generó una clasificación donde se discriminaron las dos fases donde se diferenció la fase de tener el pie en el suelo de color amarillo y de tener el pie levantado en color verde. Por otro lado, en la pierna izquierda visualizada en la figura 74 se observa este mismo comportamiento para la articulación de la rodilla.

La clasificación generada para este ejercicio presentó falencias al momento de diferenciar la fase en que se encuentra el movimiento, esto puede ser a que la imagen captada por el dispositivo según la posición no era ideal para lograr distinguir este movimiento.

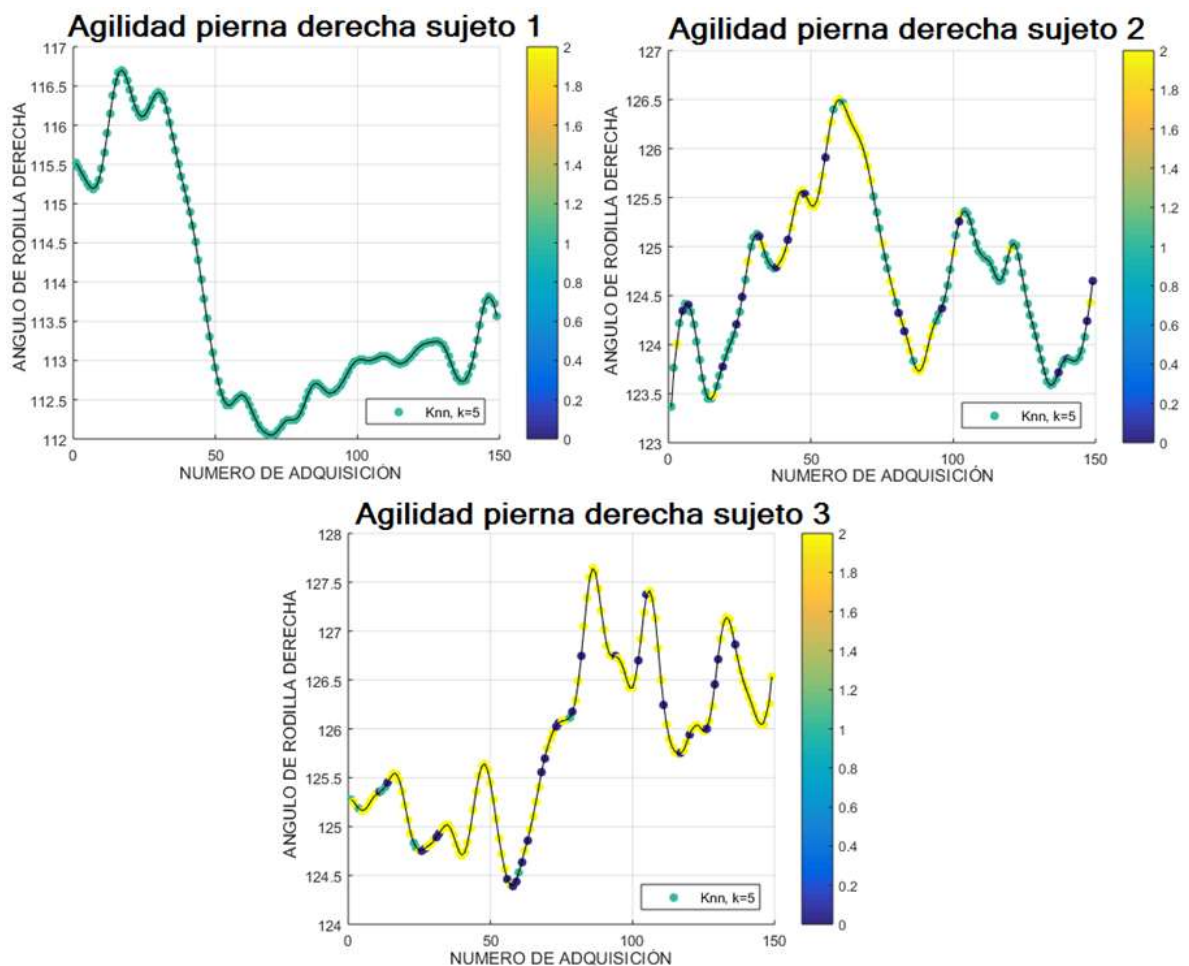


Figura 73. Clasificación por fase de movimiento en la agilidad de la pierna derecha.

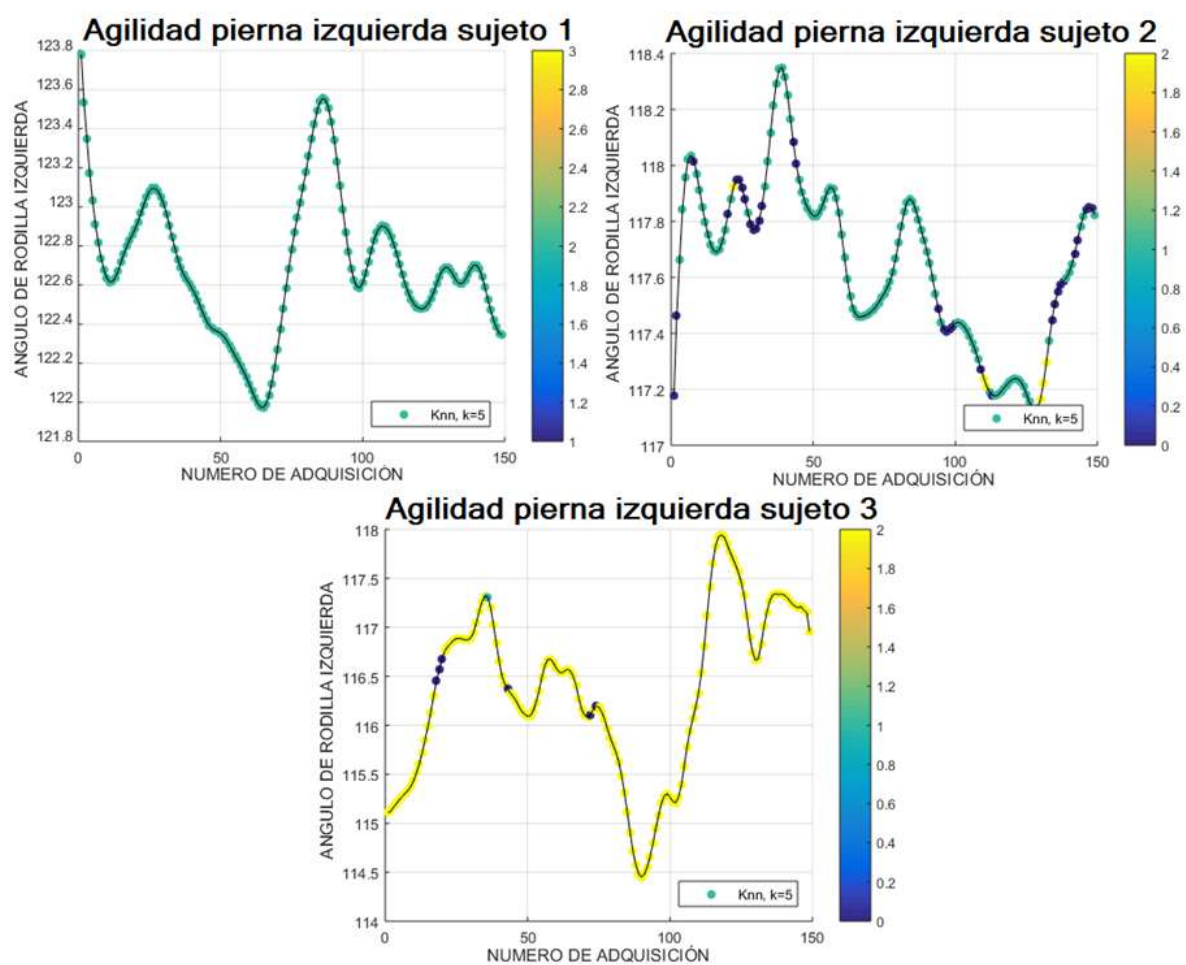


Figura 74. Clasificación por fase de movimiento en la agilidad de la pierna izquierda.

5 Conclusiones.

Los resultados de este trabajo, demuestran la viabilidad de utilizar un sistema de captura no invasivo para la evaluación cuantitativa en los aspectos motores de algunos movimientos seleccionados en un protocolo. Se logró desarrollar un protocolo de ejercicios relacionados al aspecto motor del cuerpo, extrayendo del test UPDRS los movimientos que un paciente con Parkinson puede ejecutar como lo es la marcha, levantarse de una silla, la alternación en las manos y la agilidad en el pie. Se caracterizó los movimientos por fases logrando ser distinguibles. En el movimiento de agilidad en el pie, no se consiguió una buena discriminación de las muestras adquiridas.

Las características generadas a partir de las coordenadas espaciales fueron eficientes para lograr distinguir las fases de cada movimiento ejecutado. Se logró implementar un software el cual visualizaba la persona en tiempo real, además se estableció en esta un modelo esquelético para el cuerpo de la persona. Una vez se visualizaba el modelo esquelético, este programa daba comienzo a la generación de información correspondiente a las características establecidas.

Se logró obtener una clasificación en la fase de un movimiento ejecutado a partir del algoritmo de clasificación Knn, aunque la clasificación de las muestras fue distinguible en los movimientos de marcha, sentado de pie y alternación de manos, en el movimiento de agilidad en los pies se generó una clasificación errónea en algunos sujetos analizados.

Se logró cuantificar el error de las muestras adquiridas a partir del algoritmo de validación cruzada, extrayendo parámetros de exactitud, error, sensibilidad, sensibilidad, precisión y tasa de falsos negativos; cada uno de estos parámetros se presentan con su desviación estándar, encontrando que la desviación estándar de las muestras para cada fase de movimiento fue muy pequeña reflejando una buena agrupación de las muestras adquiridas. Se observó el comportamiento de los algoritmos de reducción de dimensión para el clasificador Knn mediante la tasa de reconocimiento a partir de las componentes de baja dimensión.

La curva característica referente al centro de cadera de una persona en la marcha, evidenció una tendencia igual que la curva encontrada en la literatura, con la única diferencia que la variación del ángulo a medida que se ejecutaba la marcha fue de menor apertura, además la clasificación por fase fue distinguible, sin embargo se indaga que clasificación por fase se debe a la velocidad a la que la persona realiza el movimiento, ya que el tiempo de adquisición de las muestras por parte del dispositivo se captura en centisegundos.

Se observa que en cada movimiento ejecutado, la señal obtenida es ruidosa, a pesar de esto se puede evidenciar una tendencia característica para el movimiento ejecutado, la cual se puede entender como una curva estándar para cada movimiento discriminado por las fases establecidas.

6 Trabajos futuros.

Si bien se escogieron 4 ejercicios del aspecto motor de test UPDRS, se pretende reunir más ejercicios realizados en diferentes protocolos validados. Por otra parte se desea extraer más información a partir de las coordenadas espaciales que se agreguen al sistema como características para ayudar a distinguir las muestras por fase de movimiento. Así mismo implementar diferentes filtros para eliminar ciertas frecuencias que se inducen al sistema como ruido y que generan perturbación e incertidumbre en la señal obtenida.

Para este trabajo se utilizó un único algoritmo de clasificación el cual fue el Knn, con las variantes de los algoritmos de reducción de dimensión PCA y PCA con un Kernel gaussiano. Uno de los trabajos futuros es poder utilizar diferentes algoritmos de clasificación como máquinas de soporte vectorial (SVM), clasificador bayesiano, árboles de decisión o redes neuronales, con el fin de observar el mejor comportamiento del modelo predictivo entre las muestras. Este trabajo se implementó por código en el entorno de programación Matlab, se pretende a futuro realizar una interfaz gráfica en un software de libre uso, para que una persona pueda interactuar y desarrollar el análisis de forma didáctica y con un fácil uso.

Se pretende realizar la captura de muestras en un mocap lab, para realizar el tratamiento computacional de extracción y adquisición de muestras en un sujeto de estudio, con el fin de realizar una comparación entre los movimientos ejecutados observando el comportamiento de las curvas características por fases de cierto movimiento ejecutado.

Los pacientes analizados en este trabajo se consideran pacientes sanos sin problemas ni afecciones en los aspectos motores del cuerpo. Se pretende a futuro poder analizar pacientes con la patología de Parkinson con el fin de observar el comportamiento de las curvas características y de clasificación, para estandarizar una propuesta de método de diagnóstico.

7 Bibliografía

- [1] M. Gómez Chavarín, G. Roldan Roldan, R. Morales Espinosa, G. Pérez Soto y C. Torner Aguilar, «Mecanismos fisiopatológicos involucrados en la enfermedad de Parkinson.,» *Arch. Neurocién*, vol. 17, nº 1, pp. 25-33., 2012.
- [2] A. Antonini, G. Abbruzzese, L. Ferini Strambi, B. Tilley, J. Huang, G. Stebbins y F. Di Stasio, « Validation of the Italian version of the Movement Disorder Society—Unified Parkinson’s disease rating scale.,» *Neurological Sciences*, vol. 34, nº 5, pp. 683-687., 2013.
- [3] S. Nõmm, A. Toomela, M. Vaske, D. Uvarov y P. Taba, «An alternative approach to distinguish movements of parkinson disease patients.,» *IFAC-PapersOnLine*, vol. 49, nº 19, pp. 272-276, 2016.
- [4] B. Frades Payo, M. J. Forjaz y P. Martínez Martín, «Situación actual del conocimiento sobre calidad de vida en la enfermedad de Parkinson: I. Instrumentos, estudios comparativos y tratamientos.,» *Rev Neurol.*, vol. 49, nº 11, pp. 594-598, 2009.
- [5] R. García Ramos, E. L. Valdés, L. Ballesteros, S. Jesús y P. Mir, « Informe de la Fundación del Cerebro sobre el impacto social de la enfermedad de Parkinson en España.,» *Neurología*, vol. 31, nº 6, pp. 401-413., 2016.
- [6] M. Robinson y M. Parkinson, «Estimating anthropometry with microsoft kinect.,» *Proceedings of the 2nd International Digital Human Modeling Symposium*, vol. 1, nº 2, 2013.
- [7] A. A. Bigy, K. Banitsas, A. Badii y J. Cosmas, «Recognition of postures and Freezing of Gait in Parkinson's disease patients using Microsoft Kinect sensor.,» *Neural Engineering (NER), 2015 7th International IEEE/EMBS Conference.*, pp. 731-734, 2015.
- [8] A. Procházka, O. Vyšata, M. Vališ, O. Ľupa, M. Schätz y V. Mařík, «Use of the image and depth sensors of the Microsoft Kinect for the detection of gait disorders.,» *Neural Computing and Applications.*, vol. 26, nº 7, pp. 1621-1629, 2015.
- [9] O. Ľupa, A. Procházka, O. Vyšata, M. Schätz, J. Mareš, M. Vališ y V. Mařík, «Motion tracking and gait feature estimation for recognising Parkinson’s disease using MS Kinect.,» *Biomedical engineering online*, vol. 14, nº 1, p. 97, 2015.
- [10] M. T. Herrero Ezquerro, «Enfermedad de Parkinson.,» 2010.
- [11] M. Gratacós, «Dopamina: Funciones y Mecanismo de Acción.».
- [12] J. Jankovic, «Parkinson’s disease: clinical features and diagnosis.,» *Journal of neurology, neurosurgery & psychiatry*, vol. 79, nº 4, pp. 368-376, 2008.
- [13] G. Robles Gaiteros, «Enfermedad de Parkinson. Abordaje enfermero.,» 2016.
- [14] F. E. Micheli, 2006, Médica Panamericana, Enfermedad de Parkinson y trastornos relacionados.
- [15] S. García, B. López, E. G. Meza Dávalos, A. d. J. Villagómez Ortiz y R. Coral Vázquez1, «Breve reseña histórica de la enfermedad de Parkinson. De la descripción precipitada de la enfermedad en el siglo XIX, a los avances en biología molecular del padecimiento.,» *Medicina interna de Mexico*, vol. 26, nº 4, pp. 350-373, 2010.

- [16] C. Gomez, M. Roldan y R. Morales-Espinosa, «Mecanismos fisiopatológicos involucrados en la enfermedad de Parkinson.,» *Arch. Neurocién.(Mex. DF)*, vol. 17, nº 1, pp. 25-33, 2012.
- [17] P. Chana y D. Alburquerque, *Enfermedad de Parkinson.*, Santiago de Chile: CETRAM, 2010.
- [18] P. Chana, «Mortalidad por enfermedad de Parkinson en Chile.,» *Revista médica de Chile*, vol. 141, nº 3, pp. 327-331, 2013.
- [19] A. Hughes y D. J., «A clinicopathologic study of 100 cases of Parkinson's disease.,» *Archives of neurology*, pp. 140-148, 1993.
- [20] O. Hornykiewicz y S. Kish, «Neurochemical basis of dementia in Parkinson's disease.,» *Canadian Journal of Neurological Sciences*, vol. 11, nº S1, pp. 185-190, 1984.
- [21] M. DELONG, A. GEORGOPOULOS y M. CRUTCHER, «Cortico-basal ganglia relations and coding of motor performance.,» *Experimental Brain Research*, vol. 7, pp. 30-40., 1983.
- [22] T. JOHNSON, E. ROSVOLD y M. MISHKIN, «Projections from behaviorally-defined sectors of the prefrontal cortex to the basal ganglia, septum, and diencephalon of the monkey.,» *Experimental Neurology*, vol. 21, nº 1, pp. 20-34, 1968.
- [23] S. Ostrosky, «Características neuropsicológicas de la enfermedad de Parkinson.,» *Rev Neurol*, vol. 30, nº 8, pp. 788-796., 2000.
- [24] I. Estrada Bellmann y H. R. Martínez Rodríguez, «Diagnóstico y tratamiento de la enfermedad de Parkinson.,» *Avances*, vol. 8, nº 25, pp. 16-22, 2011.
- [25] «Asociación Cántabra de Parkinson.,» [En línea]. Available: <http://parkinsoncantabria.com/enfermedad-tratamientos/diagnostico-parkinson/>. [Último acceso: 14 11 2018].
- [26] J. Jankovic, «Parkinson's disease: clinical features and diagnosis.,» *Journal of neurology, neurosurgery & psychiatry*, vol. 79, nº 4, pp. 368-376, 2008.
- [27] M. F. Allam, A. S. Del castillo y R. F. Navas, «Factores de riesgo de la enfermedad de Parkinson.,» *Rev Neurol*, vol. 36, nº 8, pp. 749-755, 2003.
- [28] D. Calne y J. W. LANGSTON, «Aetiology of Parkinson's disease.,» *The Lancet*, vol. 322, nº 8365-8366, pp. 1457-1459., 1983.
- [29] S.-c. Li, B. Schoenberg, C. Wang, X. Cheng, D. Rui, C. Bolis y D. Schoenberg, «A prevalence survey of Parkinson's disease and other movement disorders in the People's Republic of China.,» *Archives of neurology*, vol. 42, nº 7, pp. 655-657, 1985.
- [30] A. Hughes, D. Susan y A. J. Lees, «Improved accuracy of clinical diagnosis of Lewy body Parkinson's disease.,» *Neurology*, vol. 57, nº 8, pp. 1497-1499., 2001.
- [31] W. Gibb y A. Lees, «The relevance of the Lewy body to the pathogenesis of idiopathic Parkinson's disease.,» *Journal of Neurology, Neurosurgery & Psychiatry*, vol. 51, nº 6, pp. 745-752., 1988.
- [32] H. Morales Briceño, A. Cervantes Arriaga y M. Rodríguez Violante, «Diagnóstico premotor de la enfermedad de Parkinson.,» *Gaceta médica de México*, vol. 147, nº 1, pp. 22-32, 2011.

- [33] «National Institute of Neurological Disorders and Stroke N.I.H.», 13 11 2018. [En línea]. Available: <https://www.ninds.nih.gov/About-NINDS/Who-We-Are/Advisory-Council>. [Último acceso: 15 11 2018].
- [34] J. Tapia Núñez y P. Chana Cuevas, «Diagnóstico de la enfermedad de Parkinson.», *Rev neurol*, vol. 38, nº 1, pp. 61-67., 2004.
- [35] M. M. Mouradian, «Recent advances in the genetics and pathogenesis of Parkinson disease.», *Neurology*, vol. 58, nº 179-185, p. 2, 2002.
- [36] J. Usha, «Neuroimaging of Movement Disorders.», pp. 1389-1390., 2014.
- [37] G. T. Stebbins y C. G. Goetz, «Factor structure of the Unified Parkinson's Disease Rating Scale: motor examination section. Movement disorders.», *official journal of the Movement Disorder Society.*, vol. 13, nº 4, pp. 633-636, 1998.
- [38] S. Fahn, «Members of the UPDRS development committee. Unified Parkinson's disease rating scale.», *Recent developments in Parkinson's disease*, vol. 2, pp. 293-304, 1987.
- [39] S. K. Patrick, A. A. Denington, M. J. Gauthier, D. M. Gillard y A. Prochazka, «Quantification of the UPDRS rigidity scale.», *IEEE transactions on neural systems and rehabilitation engineering.*, pp. 31-41., 2001.
- [40] M. Rodríguez Violante y A. Cervantes Arriaga, «La escala unificada de la enfermedad de Parkinson modificada por la Sociedad de Trastornos del Movimiento (MDS-UPDRS): aplicación clínica e investigación.», *Archivos de Neurociencias*, vol. 19, nº 3, pp. 157-163, 2014.
- [41] C. F. Rodríguez, H. Quintero y H. Aschner, «Movimiento del brazo humano: de los tres planos a las tres dimensiones.», *Revista de Ingeniería*, nº 22, 2005.
- [42] «International Society of Biomechanics.», 16 11 2018. [En línea]. Available: <https://isbweb.org/>. [Último acceso: 19 11 2018].
- [43] G. Wu y P. R. Cavanagh, «ISB recommendations for standardization in the reporting of kinematic data.», *Journal of biomechanics*, vol. 28, nº 10, pp. 1257-1261, 1995.
- [44] A. Kontaxis, A. Cutti, G. R. Johnson y H. E. J. Veeger, «A framework for the definition of standardized protocols for measuring upper-extremity kinematics.», *Clinical Biomechanics*, vol. 24, nº 3, pp. 246-253, 2009.
- [45] G. Wu, F. C. Van der Helm, H. Veeger, M. Makhsous, P. Van Roy, C. Anglin y F. W. Werner, «ISB recommendation on definitions of joint coordinate systems of various joints for the reporting of human joint motion—Part II: shoulder, elbow, wrist and hand.», *Journal of biomechanics*, vol. 38, nº 5, pp. 981-992, 2005.
- [46] O. P. Osorio y F. I. Peña, Artists, *Captura de movimiento utilizando el kinect para el control de una plataforma robotica controlada de forma remota por medio de seguimiento de los puntos de articulación del cuerpo*. [Art]. Universidad Tecnológica de Pereira, 2015.
- [47] «Electrolado.», 01 11 2018. [En línea]. Available: <https://www.elotrolado.net/wiki/Kinect>. [Último acceso: 20 11 2018].
- [48] S. H. Peralta Benhumea, Artist, *Interfaz de lenguaje natural usando Kinect*. [Art]. Centro de investigación y de estudios avanzados del instituto politécnico nacional. Unidad de Zacatenco. Departamento de computación, 2012.
- [49] A. Zhang, «Microsoft kinect sensor and its effect.», *IEEE multimedia*, vol. 19, nº 2, pp. 4-10, 2012.

- [50] L. Mathe, D. Samban y G. Gómez, Artists, *Estudio del funcionamiento del sensor Kinect y aplicaciones para bioingeniería..* [Art]. Universidad Nacional de Córdoba, 2012.
- [51] F. J. Vásquez Vásquez, Artist, *Brazo robótico controlado mediante sensor Kinect.* [Art]. Instituto politécnico nacional. Escuela superior de Ingeniería Mecánica y Eléctrica, 2013.
- [52] Y. Bengio y Y. Grandvalet, «No unbiased estimator of the variance of k-fold cross-validation.,» *Journal of machine learning research*, vol. 5, pp. 1089-1105, 2004.
- [53] P. Devijver y J. Kittler, *Pattern recognition: A statistical approach*, Londres: Prentice-Hall, 1982.
- [54] A. W. Moore, «Cross-validation for detecting and preventing overfitting.,» *School of Computer Science Carnegie Mellon University.*, 2001.
- [55] S. Stehman, «Selecting and interpreting measures of thematic classification accuracy.,» *Remote sensing of Environment*, vol. 62, nº 1, pp. 77-89, 1997.
- [56] I. Jolliffe, «Principal component analysis.,» *International encyclopedia of statistical science*, pp. 1094-1096, 2011.
- [57] P. R. Peres Neto, D. A. Jackson y K. M. Somers, «How many principal components? Stopping rules for determining the number of non-trivial axes revisited.,» *Computational Statistics & Data Analysis*, vol. 49, nº 4, pp. 974-997, 2005.
- [58] D. Peña, *Análisis de datos multivariantes*, España: McGraw-Hill , 2013.
- [59] Q. Wang, «Kernel principal component analysis and its applications in face recognition and active shape models.,» *arXiv preprint arXiv.*, p. 1207.3538, 2012.
- [60] B. Schölkopf, A. Smola y K. R. Müller, « Kernel principal component analysis.,» *International Conference on Artificial Neural Networks*, pp. 583-588, 1997.
- [61] N. S. Altman, «An introduction to kernel and nearest-neighbor nonparametric regression.,» *The American Statistician*, vol. 46, nº 3, pp. 175-185, 1992.
- [62] P. A. Jaskowiak y R. J. Campello, «Comparing correlation coefficients as dissimilarity measures for cancer classification in gene expression data.,» *Proceedings of the Brazilian Symposium on Bioinformatics*, pp. 1-8, 2011.
- [63] D. Coomans y D. L. Massart, «Alternative k-nearest neighbour rules in supervised pattern recognition: Part 1. k-Nearest neighbour classification by using alternative voting rules.,» *Analytica Chimica Acta*, vol. 136, pp. 15-27, 1982.
- [64] C. Sanz, «Cinesiología de la marcha humana normal.,» *Links*, pp. 1-14, 2006.
- [65] M. Eltoukhy, J. Oh, C. Kuenze y J. Signorile, «Improved kinect-based spatiotemporal and kinematic treadmill gait assessment.,» *Gait & posture*, vol. 51, pp. 77-83, 2017.
- [66] E. D. Lemaire, R. Samadi, L. Goudreau y J. Kofman, «Mechanical and biomechanical analysis of a linear piston design for angular-velocity-based orthotic control.,» *Journal of Rehabilitation Research & Development*, vol. 50, nº 1, 2013.
- [67] M. Błażkiewicz, L. Wiszomirska y A. Wit, «A new method of determination of phases and symmetry in stand-to-sit-to-stand movement.,» *International journal of occupational medicine and environmental health*, vol. 27, nº 4, pp. 660-671, 2014.
- [68] M. Kaneko, H. Okui, K. Higashi, Y. Noguchi, T. Ohya, Y. Yamashita y K. Iramina, «The comparison with the function of children's pronation and supination using

acceleration and angular velocity sensors.,» *Biomedical Engineering International Conference (BMEiCON)*, pp. 1-5, 2012.

- [69] «MathWorks,» [En línea]. Available: <https://la.mathworks.com/help/imaq/acquiring-image-and-skeletal-data-using-the-kinect.html>. [Último acceso: 03 12 2018].
- [70] G. K. R, «The biplot graphic display of matrices with application to principal component analysis,» *Biometrika*, vol. 58, n° 3, pp. 453-467, 1971.
- [71] A. Grané y A. Jach, Applications of principal component analysis (PCA) in food science and technology, John Wiley & Sons: Chichester, UK., 2014.
- [72] K. Gabriel, «The biplot graphic display of matrices with application to principal component analysis.,» *Biometrika.*, vol. 58, n° 3, pp. 453-467, 1971.

8 Anexos

Anexo 1: Tabla A1. Propiedades de imagen a color y profundidad, configuración manual [69].

Propiedades específicas del sensor de color	Descripción
Accelerometer	Devuelve el vector 3D de datos de aceleración para los sensores de color y de profundidad. Los datos se actualizan mientras el dispositivo se está ejecutando o prevvisualizando.
AutoExposure	Se utiliza para establecer un ajuste en la exposición de la imagen.
AutoWhiteBalance	Se usa para habilitar o deshabilitar el ajuste de balance de blancos automático.
BacklightCompensation	Configura los modos de compensación de contraluz para ajustar la cámara para capturar imágenes dependiendo de las condiciones ambientales.
Brightness	Indica el nivel de brillo. El rango de valores es de 0.0 a 1.0, y el valor predeterminado es 0.2156. Tenga en cuenta que esta propiedad solo es válida si Autoexposición está configurada en Habilitado.
CameraElevationAngle	Controla el ángulo de la lente del sensor. Este es el ángulo de la cámara con respecto al suelo. El valor debe ser una propiedad entera con un rango de -27 a 27 grados. El valor predeterminado es el último valor establecido, ya que se trata de una configuración fija. Configúrelo solo si desea cambiar el ángulo de la cámara. Esta propiedad es compartida con el sensor de profundidad también.
Contrast	Indica el nivel de contraste. Los valores deben estar en el rango de 0.5 a 2, con un valor predeterminado de 1.
ExposureTime	Indica el tiempo de exposición en incrementos de 1 / 10,000 de un segundo. El rango de valores es de 0 a 4000, y el valor predeterminado es 0.
FrameInterval	Indica el intervalo de fotogramas en unidades de 1 / 10,000 de segundo. El rango de valores es de 0 a 4000, y el valor predeterminado es 0.
FrameRate	Cuadros por segundo para la adquisición. Esta propiedad es de solo lectura y los valores posibles para el sensor de color son 12, 15 y 30 (predeterminado). Refleja la velocidad de fotogramas real cuando se ejecuta.

Gain	Indica un multiplicador para los valores de color RGB. El rango de valores es de 1.0 a 16.0, y el valor predeterminado es 1.0.
Gamma	Indica la medida gamma. Los valores deben estar en el rango de 1 a 2.8, con un valor predeterminado de 2.2.
Hue	Indica la configuración de tono. Los valores deben estar en el rango de -22 a 22, con un valor predeterminado de 0.
PowerLineFrequency	Opción para reducir el parpadeo causado por la frecuencia de una línea eléctrica. Los valores son 50 Hertz y 60 Hertz. El valor predeterminado es deshabilitado.
Saturation	Indica nivel de saturación. Los valores deben estar en el rango de 0 a 2, con un valor predeterminado de 1.
Sharpness	Indica nivel de nitidez. Los valores deben estar en el rango de 0 a 1, con un valor predeterminado de 0.5.
WhiteBalance	Indica la temperatura del color en grados Kelvin. El rango de valores es de 2700 a 6500 y el valor predeterminado es de 2700

Anexo 2: Tabla A2. Propiedades de imagen de profundidad para el modo seguimiento [69].

Propiedades específicas del sensor de Profundidad	Descripción
Accelerometer	Igual que en la imagen en RGB solo que opera con el sensor IR
BodyPosture	Indica si los esqueletos rastreados están de pie o sentados. Los valores están en pie (da datos de esqueleto de 20 puntos) y Sentado (da datos de esqueleto de 10 puntos). Si BodyPosture está configurado en modo Sentado, y TrackingMode está establecido en Posición, no se devuelve ninguna posición, ya que Posición es la ubicación de la articulación de la cadera y la articulación de la cadera no se rastrea en el modo Sentado.
CameraElevationAngle	Esta propiedad se comparte con el sensor de color también.
DepthMode	Indica el rango de profundidad en el mapa de profundidad. Los valores son Predeterminados (rango de 50 a 400 cm) y Cercanos (rango de 40 a 300 cm).
FrameRate	Cuadros por segundo para la adquisición. Esta propiedad es de solo lectura y se fija en 30 para el sensor de profundidad para todos los formatos. Refleja la velocidad de fotogramas real cuando se ejecuta.

IREmitter	Controla si el emisor de IR está encendido o apagado. Una ventaja de esta propiedad es que es útil cuando se usan múltiples dispositivos Kinect para evitar interferencias.
SkeletonsToTrack	Indica el ID de seguimiento de esqueleto
TrackingMode	Indica el estado de seguimiento. Los valores son: Esqueleto sigue esqueleto completo con articulaciones. Posiciona solo la posición de las articulaciones de la cadera. Desactivar deshabilita el seguimiento de la posición del esqueleto (predeterminado)

Anexo 3: Tabla A3. Propiedades de los datos esqueléticos de Microsoft Kinect [69].

Metadato	Descripción
AbsTime	Representa la marca de tiempo completa, incluida la fecha y la hora, en formato de reloj MATLAB.
FrameNumber	Representa el número de cuadro o Frame.
IsPositionTracked	Esta es una matriz booleana de 1 x 6 de valores verdaderos / falsos para el seguimiento de la posición de cada uno de los seis esqueletos. Un 1 indica que la posición está rastreada y un 0 indica que no lo está.
IsSkeletonTracked	Esta es una matriz booleana de 1 x 6 de valores verdaderos / falsos para el estado rastreado de cada uno de los seis esqueletos. Un 1 indica que se está siguiendo y un 0 indica que no.
JointDepthIndices	Si la propiedad BodyPosture se establece en Permanente, se trata de una matriz doble de 20 x 2 x 6 de coordenadas x e y para 20 articulaciones en píxeles con respecto a la imagen de profundidad, para los seis esqueletos posibles. Si BodyPosture se establece en Sentado, esto sería una matriz doble de 10 x 2 x 6 para 10 articulaciones.
JointImageIndices	Si la propiedad BodyPosture se establece en Permanente, se trata de una matriz doble de 20 x 2 x 6 de coordenadas x e y para 20 articulaciones en píxeles con respecto a la imagen en color, para los seis esqueletos posibles. Si BodyPosture se establece en Sentado, esto sería una matriz doble de 10 x 2 x 6 para 10 articulaciones.
JointTrackingState	Esta matriz de enteros de 20 x 6 contiene valores enumerados para la precisión de seguimiento de cada unión

	para los seis esqueletos. Los valores incluyen 0 no rastreado, 1 posición inferida, 2 posiciones seguidas
JointWorldCoordinates	Esta es una matriz doble de 20 x 3 x 6 de coordenadas X, Y y Z para 20 uniones, en metros desde el sensor, para los seis esqueletos posibles, si la Opción del cuerpo está configurada en Permanente. Si se establece en Sentado, este sería un doble de 10 x 3 x 6 para 10 uniones.
PositionDepthIndices	Una matriz doble de 2 x 6 de las coordenadas X e Y de cada esqueleto en píxeles con respecto a la imagen de profundidad.
PositionImageIndices	Una matriz doble de 2 x 6 de las coordenadas X e Y de cada esqueleto en píxeles en relación con la imagen en color.
PositionWorldCoordinates	Una matriz doble de 3 x 6 de las coordenadas X, Y y Z de cada esqueleto en metros con respecto al sensor.
RelativeFrame	Este doble de 1 x 1 representa el número de cuadro relativo a la ejecución de un disparador si se utiliza el disparador.
SegmentationData	Matriz doble de tamaño de imagen con cada píxel asignado a un esqueleto rastreado / detectado, representado por los números 1 a 6. Este mapa de segmentación es un mapa de bits con valores de píxeles correspondientes al índice de la persona en el campo de visión que está más cerca de la cámara en esa posición de píxel. Un valor de 0 significa que no hay un esqueleto rastreado.
SkeletonTrackingID	Esta matriz de enteros 1 x 6 contiene los ID de seguimiento de los seis esqueletos. Las identificaciones de seguimiento son generadas por el Kinect y cambian de adquisición a adquisición.
TriggerIndex	Este es un doble de 1 x 1 y representa el desencadenante con el que se asocia el evento si se utiliza el desencadenante.

Códigos Implementados.

Anexo 4: Código 1. CapturaMovimientos

```
clc;clear all;close all; imagreset;
hwInfo = imaqhwinfo('kinect');
colorVid = videoinput('kinect',1,'RGB_640x480');
depthVid = videoinput('kinect',2);
```

```

srcColor = getselectedsource(colorVid);
srcDepth = getselectedsource(depthVid);
set(srcDepth, 'TrackingMode', 'Skeleton')
set(srcDepth, 'BodyPosture', 'Standing')
fnum=101; %150 en movimiento
TxFrame=zeros(fnum,1);
%CameraElevationAngle
colorVid.FramesPerTrigger = 1;
depthVid.FramesPerTrigger = 1;
colorVid.TriggerRepeat = Inf;
depthVid.TriggerRepeat = Inf;
triggerconfig([colorVid depthVid], 'manual');
start([colorVid depthVid]);
skl=[];
tic

%%inicializacion de Variables
jointCoordinates = zeros(20,3,fnum);
jointCoordinatesCorreg=zeros(20,3,fnum-1);
VG=zeros(fnum,3);
EjesOrientadosArticulacion=zeros(15,3,fnum-1);
AngulodeSegmentos=zeros(15,1,fnum-1);
DistanciaaaCG=zeros(15,1,fnum-1);
posicionCG=zeros(fnum-1,3);
CentroGravedad=zeros(3,fnum-1);
CG=zeros(fnum-1,3);
Dcentrogravedad=zeros(fnum-1,1);
DCG=zeros(fnum-1,1);
%Para las muestras: M 94, SDP 94, AM 40, PD 22, PI 22.
muestras=zeros(fnum-1,94);
EOA=zeros(fnum-1,45);
AS=zeros(fnum-1,15);
DCC=zeros(fnum-1,15);
deltatetha=zeros(15,1,fnum-1);
deltatime=zeros(fnum-1,1);
velocityangular=zeros(15,1,fnum-1);
VA=zeros(fnum-1,15);
CGcad=zeros(fnum-1,3);
Origenhipcenter=zeros(1,3,fnum-1);
spine=zeros(1,3,fnum-1);
hiprigh=zeros(1,3,fnum-1);
xcad=zeros(1,3,fnum-1);
ycad=zeros(1,3,fnum-1);
zcad=zeros(1,3,fnum-1);
u=zeros(1,3,fnum-1);
proyxcad=zeros(1,1,fnum-1);
proyycad=zeros(1,1,fnum-1);
proyycad=zeros(1,1,fnum-1);
PXCad=zeros(fnum-1,1);
PYCad=zeros(fnum-1,1);
PZZCad=zeros(fnum-1,1);
art=1:9;
Nart=size(art,2);
i=1;

while i ~= fnum
    trigger([colorVid depthVid]);
    [depthMap,frameDataDepth,depthMetaData] = getdata(depthVid);

```

```

[imgColorAll, metaDataColorAll] = getdata(colorVid);
imgColor=imgColorAll(:,:, :,1);

if any(depthMetaData.IsSkeletonTracked)==0
    imshow(imgColor);
else
    skl=find(depthMetaData.IsPositionTracked);
    VG(i,:)=srcDepth.Accelerometer;
    skeletonJoints =
depthMetaData.JointDepthIndices(:,:,depthMetaData.IsSkeletonTracked);
    jointIndices = depthMetaData.JointDepthIndices(:, :, skl(1));
    jointCoordinates(:, :,i) =
depthMetaData.JointWorldCoordinates(:, :, skl(1));

posicionCG(i,:)=depthMetaData.PositionWorldCoordinates(:,skl(1));
    if mean(mean(jointCoordinates(:, :,i)))~=0
        i=i+1;

    end
    if isnan(jointCoordinates(:, :,i))
        jointCoordinates(:, :,i)=[];
    end
    imshow(imgColor);
    hold on
    DibujarEsqueleto(jointIndices, imgColor, skl)
    hold off;

end
TxFrame(i)=toc;
if i==101
    TxFrame(i)=[];
end
end
stop(depthVid)
TTotal=toc;
imaqreset;
jointCoordinates(:, :, fnum) = [];
VG(fnum, :)=[];
fnum=fnum-1;

for k=1:fnum
    for l=1:20

jointCoordinatesCorreg(l, :,k)=CorregKinect(VG(k, :), jointCoordinates(l, :,k
));
        Origenhipcenter(l, :,k)=jointCoordinatesCorreg(l, :,k); %centro
cadera
        spine(l, :,k)=jointCoordinatesCorreg(2, :,k); %torzo
        hiprighth(l, :,k)=jointCoordinatesCorreg(13, :,k); %cadera
derecha
        ycad(l, :,k)=spine(l, :,k)-Origenhipcenter(l, :,k);
        u(l, :,k)=hiprighth(l, :,k)-Origenhipcenter(l, :,k);
        zcad(l, :,k)=cross(u(l, :,k), ycad(l, :,k));
        xcad(l, :,k)=cross(ycad(l, :,k), zcad(l, :,k));

    end

end
end

```

```

    %Orientacion para cada articulacion (Nuevos Ejes)
    for k=1:fnum
        CentroGravedad(:,k)=CorregKinect(VG(k,:),posicionCG(k,:));
        CG(k,:)=reshape(CentroGravedad(:,k)',3,1);

EjesOrientadosArticulacion(:, :,k)=OrientacionEjes(jointCoordinatesCorreg(
:,:,k));

AngulodeSegmentos(:,k)=AnguloEntreSegmentos(jointCoordinatesCorreg(:, :,k)
);

DistanciaaCG(:,k)=DistaciaArticulacionaCG(jointCoordinatesCorreg(:, :,k));
    EOA(k,:)=reshape(EjesOrientadosArticulacion(:, :,k),45,1);
    AS (k,:)=reshape(AngulodeSegmentos(:, :,k),15,1);
    DCC(k,:)=reshape(DistanciaaCG(:, :,k),15,1);
    CGcad(k,:)=CG(k,:)-Origenhipcenter(1, :,k);
    Dcentrogravedad(k,:)=norm(CGcad(k,:));
    DCG(k,:)=reshape(Dcentrogravedad(k),1,1);
    proycad(k)=dot(xcad(1, :,k),CG(k,:));
    proyycad(k)=dot(ycad(1, :,k),CG(k,:));
    proyycad(k)=dot(zcad(1, :,k),CG(k,:));
    PXCad(k,:)=reshape(proycad(k),1,1);
    PYCad(k,:)=reshape(proyycad(k),1,1);
    PZZCad(k,:)=reshape(proyycad(k),1,1);
    end

    for k=1:fnum-1
        deltatheta(:,k)=AngulodeSegmentos(:,k+1)-AngulodeSegmentos(:,k);
        deltatime(k)=TxFrame(k+1)-TxFrame(k);
        velocityangular(:,k)=deltatheta(:,k)/deltatime(k);
        VA(k,:)=reshape(deltatheta(:,k),15,1);

    end

    %%Eleccion del movimiento
    %HipCenter = 1;Spine = 2;ShoulderCenter = 3;Head = 4;ShoulderLeft
= 5;ElbowLeft = 6;WristLeft = 7;HandLeft = 8;ShoulderRight = 9;ElbowRight
= 10;WristRight = 11;HandRight = 12;HipLeft = 13;
    %KneeLeft = 14;AnkleLeft = 15;FootLeft = 16;HipRight =
17;KneeRight = 18;AnkleRight = 19;FootRight = 20;
    %Miembros Superiores=1:9;
    %Miembros Inferiores=9:15;
    %brazo derecho BD=2:4
    %brazo izquierdo BI=5:7
    %pie derecho PD=10:12
    %pie izquierdo PI=13:15

    %para los brazos
    % ASBD=AS(:,2:4);
    % ASBI=AS(:,5:7);
    % ASB=[ASBD ASBI];
    % DCCBD=DCC(:,2:4);
    % DCCBI=DCC(:,5:7);
    % DCCB=[DCCBD DCCBI];
    % EOABDx=EOA(:,2:4);
    % EOABDy=EOA(:,17:19);
    % EOABDz=EOA(:,32:34);
    % EOABIx=EOA(:,5:7);
    % EOABIy=EOA(:,20:22);

```

```

%      EOABiz=EOA(:,35:37);
%      EOAB=[EOABDx EOABDy EOABDz EOABIx EOABIy EOABiz];%100x18
%      VABD=VA(:,2:4);
%      VABI=VA(:,5:7);
%      VAB=[VABD VABI];

% Para el pie derecho
%      ASPD=AS(:,10:12);
%      DCCPD=DCC(:,10:12);
%      EOAPDx=EOA(:,10:12);
%      EOAPDy=EOA(:,25:27);
%      EOAPDz=EOA(:,40:42);
%      EOAPD=[EOAPDx EOAPDy EOAPDz];
%      VAPD=VA(:,10:12);

% % Para el pie Izquierdo
%      ASPI=AS(:,13:15);%100x3
%      DCCPI=DCC(:,13:15); %100x4
%      EOAPIx=EOA(:,13:15);
%      EOAPIy=EOA(:,28:30);
%      EOAPIz=EOA(:,43:45);
%      EOAPI=[EOAPIx EOAPIy EOAPIz];%100x9
%      VAPI=VA(:,13:15);%100x3

%Muestras para el brazo Caracteristicas=40
%muestras=[EOAB ASB DCCB VAB DCG PXCad PYCad PZZCad];

%Muestras para la pierna derecha caracteristicas=22
%muestras=[EOAPD ASPD DCCPD VAPD DCG PXCad PYCad PZZCad];

%Muestras para la pierna izquierda caracteristicas=22
%muestras=[EOAPI ASPI DCCPI VAPI DCG PXCad PYCad PZZCad];

% Muestras para marcha y sentado de pie
% for k=1:fnum
%     muestras(k,:)= [EOA(k,:) AS(k,:) DCC(k,:) VA(k,:) DCG(k,:)
PXCad(k,:) PYCad(k,:) PZZCad(k,:)];
% end

% Marcha
%save('Sj10MFase8.mat','muestras')
% Sentado de Pie
%save('Sj10SDPFase3.mat','muestras')
% Alternacion manos
%save('Sj10AMFase2.mat','muestras')
% Agilidad pie derecho
%save('Sj10APDFase2.mat','muestras')
% Agilidad pie Izquierdo
%save('Sj10APIFase2.mat','muestras')

%Movimiento
%save('AgilidadPIA3.mat','muestras')

%prueba lab CIDT      %1 de pie, 2 sentado, 3 pronacion manos, 4 supinacion
manos, 5, fase 1 y 4, 6 marcha agilida pie .
%save('CIDT1.mat','muestras')

```

Anexo 5: Código 2. DibujarEsqueleto

```
function [] = DibujarEsqueleto(skeleton, image, nSkeleton)

% Muestra un marco de imagen RGB con ubicaciones de unión esqueleto
superpuestas
% skeleton: ubicaciones de imágenes de esqueleto de 20x2x1 o 20x2x2
devueltas por
% Kinect para Windows
% imagen: la imagen RGB correspondiente al marco del esqueleto.
% nSkeleton: Número de esqueletos

% Aquí está el orden de las articulaciones devueltas por Kinect para
Windows
%     HipCenter = 1;
%     Spine = 2;
%     ShoulderCenter = 3;
%     Head = 4;
%     ShoulderLeft = 5;
%     ElbowLeft = 6;
%     WristLeft = 7;
%     HandLeft = 8;
%     ShoulderRight = 9;
%     ElbowRight = 10;
%     WristRight = 11;
%     HandRight = 12;
%     HipLeft = 13;
%     KneeLeft = 14;
%     AnkleLeft = 15;
%     FootLeft = 16;
%     HipRight = 17;
%     KneeRight = 18;
%     AnkleRight = 19;
%     FootRight = 20;

%Muestra la imagen en RGB
imshow(image);
%imshow
% Mapa esquemático de conexión para unir las articulaciones
SkeletonConnectionMap = [[1 2]; % Spine
                        [2 3];
                        [3 4];
                        [3 5]; %Left Hand
                        [5 6];
                        [6 7];
                        [7 8];
                        [3 9]; %Right Hand
                        [9 10];
                        [10 11];
                        [11 12];
                        [1 17]; % Right Leg
                        [17 18];
                        [18 19];
                        [19 20];
                        [1 13]; % Left Leg
                        [13 14];
                        [14 15];
```

```

[15 16]];

% Dibuja los esqueletos en la imagen RGB
for i = 1:19

    if nSkeleton > 0
        X1 = [skeleton(SkeletonConnectionMap(i,1),1,1)
skeleton(SkeletonConnectionMap(i,2),1,1)];
        Y1 = [skeleton(SkeletonConnectionMap(i,1),2,1)
skeleton(SkeletonConnectionMap(i,2),2,1)];
        line(X1,Y1, 'LineWidth', 1, 'LineStyle', '-', 'Marker', 'o',
'Color', 'y');
    end
    if nSkeleton > 1
        X2 = [skeleton(SkeletonConnectionMap(i,1),1,2)
skeleton(SkeletonConnectionMap(i,2),1,2)];
        Y2 = [skeleton(SkeletonConnectionMap(i,1),2,2)
skeleton(SkeletonConnectionMap(i,2),2,2)];
        line(X2,Y2, 'LineWidth', 2, 'LineStyle', '-', 'Marker', 'o',
'Color', 'g');
    end
    hold on;
end

```

Anexo 6: Código 3. CorregKinect

```

function ABtheta = CorregKinect(G,P)
theta=acos(G(2)/norm(G)); %angulo
YxG=[-G(3),0,G(1)]; %B
%A=Punto
%AB,theta=C= Punto Rotado
%A=AparB+AperB;
%AparB=(A.B)/(B.B)*B
AparB=(P*YxG)/(norm(YxG))*(YxG); %fila*columna
%AperB=A-AparB
AperB=P-(AparB);
%w=BxAperB;
w=cross(YxG,AperB);
%x1=(cos(theta))/(abs(AperB))
x1=(cos(theta))/(norm(AperB));
%x2=(sen(theta))/(abs(w))
x2=(sin(theta))/(norm(w));
%AperBtheta=(abs(AperB))*((x1)(AperB))+((x2)(w))
AperBtheta=(norm(AperB))*((x1)*(AperB))+((x2)*(w));
%ABtheta=AperBtheta + AparB
ABtheta=AperBtheta + AparB;
end

```

Anexo 7: Código 4. OrientacionEjes

```

function A = OrientacionEjes(Coordenadascorregidas)
%=[proximal, central, distal]
Indices=[5,3,9;
        6,5,3;
        7,6,5;
        8,7,6;

```

```

        3,9,10;
        9,10,11;
        10,11,12;
        3,2,1;
        13,1,17;
        1,13,14;
        13,14,15;
        14,15,16;
        1,17,18;
        17,18,19;
        18,19,20];

A=zeros(15,3);
u=zeros(1,3);
v=zeros(1,3);

porigen=Coordenadascorregidas(2, :, :);
pproximal=Coordenadascorregidas(3, :, :);
pdistal=Coordenadascorregidas(1, :, :);
uCG=pproximal-porigen;
v=pdistal-porigen;
EjeYCG=cross(uCG,v);
EjeZCG=cross(uCG,EjeYCG);

for i=1:15
    porigen=Coordenadascorregidas(Indices(i,2), :, :);
    pproximal=Coordenadascorregidas(Indices(i,1), :, :);
    pdistal=Coordenadascorregidas(Indices(i,3), :, :);
    u=pproximal-porigen;
    v=pdistal-porigen;
    EjeY=cross(u,v);
    EjeZ=cross(u,EjeY);
    %
    A(i,1,:)=u;
    %
    A(i,2,:)=EjeY;
    %
    A(i,3,:)=EjeZ;
    A(i,1)=acosd(dot(uCG,u)/(sqrt(sum(uCG.^2)*sum(u.^2))));

A(i,2)=acosd(dot(EjeYCG,EjeY)/(sqrt(sum(EjeYCG.^2)*sum(EjeY.^2))));

A(i,3)=acosd(dot(EjeZCG,EjeZ)/((sqrt(sum(EjeZCG.^2)*sum(EjeZ.^2)))));
end
end

```

Anexo 8: Código 5. AnguloEntreSegmentos

```

function B = AnguloEntreSegmentos(Coordenadascorregidas)
Indices=[5,3,9;
        6,5,3;
        7,6,5;
        8,7,6;
        3,9,10;
        9,10,11;
        10,11,12;
        3,2,1;
        13,1,17;
        1,13,14;

```



```

        13,14,15;
        14,15,16;
        1,17,18;
        17,18,19;
        18,19,20];

B=zeros(15,1);
c=zeros(1,3);
d=zeros(1,3);

    for i=1:15
        porigen=Coordenadascorregidas(Indices(i,2),:,:,:) ;
        pproximal=Coordenadascorregidas(Indices(i,3),:,:,:) ;
        pdistal=Coordenadascorregidas(Indices(i,1),:,:,:) ;
        c=pproximal-porigen;
        d=pdistal-porigen;
        B(i)=acosd((dot(c,d))/(norm(c)*norm(d)));
    end
end

```

Anexo 9: Código 6. DistanciaArticulacionCG

```

function DaCG = DistaciaArticulacionaCG(Coordenadascorregidas)
    %=[proximal, central, distal]
    Indices=[1;2;3;5;6;7;9;10;11;13;14;15;17;18;19];

    DaCG=zeros(15,1);
    porigen=Coordenadascorregidas(Indices(1),:,:,:) ;
    for i=1:15
        articulacion=Coordenadascorregidas(Indices(i),:,:,:) ;
        resta=articulacion-porigen;
        DaCG(i)=sqrt(sum(resta.^2));
    end
end

```

Anexo 10: Código 7. Train_Test

```

function Resultado=
Train_Test(MuestraTrain,LabelTrain,MuestraTest,LabelTest)

mdl=fitcknn(MuestraTrain,LabelTrain,'NumNeighbors',5);
Prediccion=zeros(size(LabelTest));

for i=1:size(LabelTest,1)
    Prediccion(i)=predict(mdl,MuestraTest(i,:));
end
[~,Resultado,~]= confusion.getMatrix(LabelTest,Prediccion);

end

```

Anexo 11: Código 8 LeerMuestrasParkinson

```

clc;clear all;close all;
N =2000;      %M=8000; SDP=3000; AM=2000; APD=2000; API=2000;

```

```

E=22;          %M=94,   SDP=94;   AM=40;   APD=22;   API=22;
p=20;
Muestras = zeros(N,E);
Label = zeros(N,1);
cont = 1;
%Indice j para M=7, SDP=3, AM=2, APD=2, API=2.
for i=1:10
    for j=1:2
        %load(['Sj' num2str(i) 'MFase' num2str(j) '.mat']) %Lee Marcha
        %load(['Sj' num2str(i) 'SDPFase' num2str(j) '.mat']) %Lee SDP
        %load(['Sj' num2str(i) 'AMFase' num2str(j) '.mat']) %Lee AM
        %load(['Sj' num2str(i) 'APDFase' num2str(j) '.mat']) %Lee APD
        load(['Sj' num2str(i) 'APIFase' num2str(j) '.mat']) %Lee API
        for k = 1:size(muestras,1)
            Muestras(cont,:) = muestras(k,:);
            Label(cont) = j;
            cont = cont +1;
        end
    end
end

%Knn
tipoCV='kfold'; % kfold o holdout, tipos de validación.
paramCV=10;
fun=@(MuestraTrain,LabelTrain,MuestraTest,LabelTest)
Train_Test(MuestraTrain,LabelTrain,MuestraTest,LabelTest);
valErrorKnn=crossval(fun,Muestras,Label,tipoCV,paramCV);

%PCA
[Evec, Eval] = pca(Muestras);
for q=1:p
    A=Evec(:,1:q);
    Yld=Muestras*A;
    fun=@(MuestraTrain,LabelTrain,MuestraTest,LabelTest)
    Train_Test(MuestraTrain,LabelTrain,MuestraTest,LabelTest);
    valErrorPCA=crossval(fun,Yld,Label,tipoCV,paramCV);
    KnnA(q)=valErrorPCA.Accuracy;
    knnAmean(q)=mean(KnnA)
end

figure
scatter3(Yld(:,1),Yld(:,2),Yld(:,3),3,Label)
title('AGRUPACION DE DATOS PCA')

%KernelPCA
D=pdist2(Muestras,Muestras);
K=exp(-(D.^2)/((2)*(400^2)));
[Eveck, Evalk] = pca(K);
for q=1:p
    Ak=Eveck(:,1:q);
    YKld=K*Ak;
    fun=@(MuestraTrain,LabelTrain,MuestraTest,LabelTest)
    Train_Test(MuestraTrain,LabelTrain,MuestraTest,LabelTest);
    valErrorKPCA=crossval(fun,YKld,Label,tipoCV,paramCV);
    KnnKPCAA(q)=valErrorKPCA.Accuracy;
    knnKPCAmean(q)=mean(KnnKPCAA)
end

```

```

figure
scatter3(YKld(:,1),YKld(:,2),YKld(:,3),5,Label)
title('AGRUPACION DE DATOS KERNEL-PCA')

for l=1:paramCV
%Knn
KnnA(l)=valErrorKnn(l).Accuracy;
KnnE(l)=valErrorKnn(l).Error;
KnnSE(l)=valErrorKnn(l).Sensitivity;
KnnSP(l)=valErrorKnn(l).Specificity;
KnnP(l)=valErrorKnn(l).Precision;
KnnFPR(l)=valErrorKnn(l).FalsePositiveRate;

%KnnPCA
KnnPCAA(l)=valErrorPCA(l).Accuracy;
KnnPCAEL(l)=valErrorPCA(l).Error;
KnnPCASE(l)=valErrorPCA(l).Sensitivity;
KnnPCASP(l)=valErrorPCA(l).Specificity;
KnnPCAP(l)=valErrorPCA(l).Precision;
KnnPCAFPR(l)=valErrorPCA(l).FalsePositiveRate;

%KnnKPCA
KnnKPCA(l)=valErrorKPCA(l).Accuracy;
KnnKPCAEL(l)=valErrorKPCA(l).Error;
KnnKPCASE(l)=valErrorKPCA(l).Sensitivity;
KnnKPCASP(l)=valErrorKPCA(l).Specificity;
KnnKPCAP(l)=valErrorKPCA(l).Precision;
KnnKPCAFPR(l)=valErrorKPCA(l).FalsePositiveRate;
end

meanKnn=[mean(KnnA) std(KnnA) mean(KnnE) std(KnnE) mean(KnnSE)
std(KnnSE) mean(KnnSP) std(KnnSP) mean(KnnP) std(KnnP) mean(KnnFPR)
std(KnnFPR)]
meanKnnPCA=[mean(KnnPCAA) std(KnnPCAA) mean(KnnPCAEL) std(KnnPCAEL)
mean(KnnPCASE) std(KnnPCASE) mean(KnnPCASP) std(KnnPCASP) mean(KnnPCAP)
std(KnnPCAP) mean(KnnPCAFPR) std(KnnPCAFPR)]
meanKnnKPCA=[mean(KnnKPCA) std(KnnKPCA) mean(KnnKPCAEL) std(KnnKPCAEL)
mean(KnnKPCASE) std(KnnKPCASE) mean(KnnKPCASP) std(KnnKPCASP)
mean(KnnKPCAP) std(KnnKPCAP) mean(KnnKPCAFPR) std(KnnKPCAFPR)]

figure
plot(1:p,knnAmean,'--',1:p,knnKPCAAMean,':')
title('TASA DE RECONOCIMIENTO')
ylabel('Porcentaje (%)')
xlabel('Dimensionalidad')
legend('PCA','KPCA')
grid on

```

Anexo 12: Código 9. ComparacionMovimientos

```

clc;clear all;close all;
N=8000; %M=8000; SDP=3000; AM=2000; APD=2000; API=2000;
E=94; %M=94, SDP=94; AM=40; APD=22; API=22;
Muestras = zeros(N,E);
Label = zeros(N,1);

```

```

cont = 1;
fa=149;
%fa 150 # de adquisiciones que se estableció para la captura en continuo
MuestraMovimiento=zeros(fa,E); %M=94, SDP=94; AM=40; APD=22;
API=22;
contM=1;

for i=1:10
    for j=1:7
        load(['Sj' num2str(i) 'MFase' num2str(j) '.mat']) %Lee Marcha
        %load(['Sj' num2str(i) 'SDPFase' num2str(j) '.mat']) %Lee SDP
        %load(['Sj' num2str(i) 'AMFase' num2str(j) '.mat']) %Lee AM
        %load(['Sj' num2str(i) 'APDFase' num2str(j) '.mat']) %Lee APD
        %load(['Sj' num2str(i) 'APIFase' num2str(j) '.mat']) %Lee API
        for k = 1:size(muestras,1)
            Muestras(cont,:) = muestras(k,:);
            Label(cont) = j;
            Labelknn(cont) = j;
            cont = cont +1;
        end
    end
end

load(['MarchaAA4.mat'])
for k = 1:size(muestras,1)
    MuestraMovimiento(contM,:) = muestras(k,:);
    contM = contM +1;
end

%Knn clasificador
mdlknn=fitcknn(Muestras,Label,'NumNeighbors',5);
Predicionknn=zeros(fa,1);
%PCA
[Evec, Eval] = pca(Muestras);
A=Evec(:,1:30);%40
Yld=Muestras*A;
mdl=fitcknn(Yld,Label,'NumNeighbors',5);
Predicion=zeros(fa,1);
Yldpca=MuestraMovimiento*A;

for i=1:fa
    %Knn clasificador

[labelknn,scoreknn,costknn]=predict(mdlknn,MuestraMovimiento);
    ScoreMaxknn=max(scoreknn,[],2);
    Predicionknn(i)=labelknn(i);
    Predicionknn(ScoreMaxknn<0.70)=0;

    %PCA
    [label,score,cost]=predict(mdl,Yldpca);
    ScoreMax=max(score,[],2);
    proScore=sum(ScoreMax)/fa;
    Predicion(i)=label(i);
    Predicion(ScoreMax<0.70)=0;
end

%
imgF1 = imread('Fase1.png');
%
imgF2 = imread('Fase2.png');
%
imgF3 = imread('Fase3.png');

```

```

%         imgF4 = imread('Fase4.png');
%         imgF5 = imread('Fase5.png');
%         imgF6 = imread('Fase6.png');
%         imgF7 = imread('Fase7.png');
        ima1 = imread('am1.png');
        ima2 = imread('am2.png');
    img1 = imread('1.png');
    img2 = imread('2.png');
    img3 = imread('3.png');

    %Knn
    figure
    xknn=1:1:fa;
    yfknn=Prediccionknn;
    ycknn=smooth(smooth(smooth(MuestraMovimiento(:,86))));
    subplot(2,1,1)

    [hAxknn,hLine1knn,hLine2knn]=plotyy(xknn,yfknn,xknn,ycknn,'stem','plot');
    title('MARCHA SUJETO 1 NIVEL 3: NORMAL')
    xlabel('NÚMERO DE ADQUISICION')
    ylabel(hAxknn(1),'FASE') % left y-axis
    ylabel(hAxknn(2),'ANGULO DE ARTICULACIÓN') % right y-axis
    legend('Knn, k=5')
    subplot(2,1,2)
    scatter(xknn,ycknn,[],Prediccionknn,'filled')
    xlabel('FASE DE MOVIMIENTO')
    ylabel('ANGULO')
    c = colorbar('southoutside');
    hold on
    plot(ycknn,'k')
    legend('Knn, k=7','Location','southwest')
    grid on

    figure
    scatter(xknn,ycknn,[],Prediccionknn,'filled')
    title('RODILLA DERECHA SUJETO 2')
    xlabel('NUMERO DE ADQUISICIÓN')
    ylabel('VELOCIDAD ANGULAR')
    c = colorbar;
    hold on
    plot(ycknn,'k')
    legend('Knn, k=5','Location','southeast')
    grid on

    %PCA
    figure
    x=1:1:fa;
    yf=Prediccion;
    yc=smooth(smooth(smooth(MuestraMovimiento(:,86))));
    subplot(2,1,1)
    [hAx,hLine1,hLine2]=plotyy(x,yf,x,yc,'stem','plot');
    title('MARCHA SUJETO 1 NIVEL 3: NORMAL')
    xlabel('NÚMERO DE ADQUISICION')
    ylabel(hAx(1),'FASE') % left y-axis
    ylabel(hAx(2),'ANGULO DE ARTICULACIÓN') % right y-axis
    legend('PCA-Knn, k=5')

```

```

subplot(2,1,2)
scatter(x,yc,[],Prediccion,'filled')
xlabel('FASE DE MOVIMIENTO')
ylabel('ANGULO')
c = colorbar('southoutside');
hold on
plot(yc,'k')
legend('PCA-Knn, k=5','Location','southwest')
grid on

figure
scatter(x,yc,[],Prediccion,'filled')
xlabel('NUMERO DE ADQUISICIÓN')
ylabel('ANGULO POR FASE DE MOVIMIENTO')
c = colorbar;
hold on
plot(yc,'k')
legend('PCA-Knn, k=5','Location','southwest')
grid on

figure
[X,Y]=meshgrid(x,yc);
Z=meshgrid(Prediccion,Prediccion);
contourf(X,Y,Z)
colorbar
hold on
plot(yc,'r','LineWidth',2)
title('Alternación de Manos sujeto 1')
xlabel('NUMERO DE ADQUISICIÓN')
ylabel('VELOCIDAD ANGULAR')
% image('CData',imgF1,'XData',[32 37],'YData',[-5 -3])
% image('CData',imgF2,'XData',[34 39],'YData',[3 5])
% image('CData',imgF3,'XData',[35 40],'YData',[-3 -1])
% image('CData',imgF4,'XData',[38 43],'YData',[1 3])
% image('CData',imgF5,'XData',[49 54],'YData',[-5 -3])
% image('CData',imgF6,'XData',[50 55],'YData',[-3 -1])
% % image('CData',imgF7,'XData',[55 60],'YData',[-5 -3])
% image('CData',ima1,'XData',[20 30],'YData',[1 2])
% image('CData',ima2,'XData',[29 39],'YData',[-2 -1])
% image('CData',img3,'XData',[88 98],'YData',[1 2])
grid on

```

Anexo 13: Ficha de prueba.

FORMATO-ENCUESTA DE PARTICIPACION PARA LA PRUEBA DEL PROYECTO:

“Evaluación del movimiento en pacientes con párkinson utilizando técnicas computacionales para la automatización del protocolo UPDRS mediante el Kinect”

GRUPO DE INVESTIGACION INGENIERIA BIOMEDICA Y CIENCIAS FORENSES
BIOIF

Fecha :	
Nombre:	
Edad:	
Sexo:	Masculino____ Femenino____
Ocupación:	

Autoriza divulgar los datos obtenidos al llevar a cabo la presentación de la prueba. Si____, No____.

Presenta anomalías o problemas al momento de realizar ejercicios físicos. Si____, No____. Cual_____.

Esta diagnosticado con alguna patología, la cual limita la realización de actividad física. Si____, No____. Cual_____.

Ha presentado fracturas, traumas o alguna lesión grave que impide el movimiento libre de los segmentos del cuerpo. Si____, No____. Cual_____.

Tiene algún familiar que presente una enfermedad neurodegenerativa, o que presente limitaciones con el movimiento del cuerpo. Si____, No____. Cual_____.

Practica algún deporte Si____, No____. Cual_____.

Anexo 14: validación de las muestras en la marcha.

Movimiento de Marcha					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9935 \pm 0.0029	0.0056 \pm 0.0021	0.9943 \pm 0.0020	0.9992 \pm 0.0003	0.9943 \pm 0.0020	0.0008 \pm 0.0003
PCA – Knn, k = 5					
0.9942 \pm 0.0036	0.0057 \pm 0.0036	0.9944 \pm 0.0035	0.9992 \pm 0.0005	0.9942 \pm 0.0035	0.0008 \pm 0.0005
KPCA – Knn, k = 5					
0.9860 \pm 0.0054	0.0054 \pm 0.0140	0.9862 \pm 0.0053	0.9980 \pm 0.0008	0.9860 \pm 0.0052	0.0020 \pm 0.0008
Knn , k = 7					
0.9909 \pm 0.0038	0.0069 \pm 0.0026	0.9931 \pm 0.0026	0.9990 \pm 0.0004	0.9932 \pm 0.0026	0.0010 \pm 0.0004
PCA – Knn, k = 7					
0.9931 \pm 0.0022	0.0069 \pm 0.0022	0.9931 \pm 0.0023	0.9990 \pm 0.0003	0.9932 \pm 0.0023	0.0010 \pm 0.0003
KPCA – Knn, k = 7					
0.9830 \pm 0.0047	0.0170 \pm 0.0047	0.9830 \pm 0.0048	0.9976 \pm 0.0007	0.9829 \pm 0.0051	0.0024 \pm 0.0007
Knn, k = 9					
0.9888 \pm 0.0035	0.0087 \pm 0.0032	0.9912 \pm 0.0033	0.9987 \pm 0.0005	0.9913 \pm 0.0031	0.0013 \pm 0.0005
PCA – Knn, k = 9					
0.9904 \pm 0.0037	0.0096 \pm 0.0037	0.9903 \pm 0.0036	0.9986 \pm 0.0005	0.9905 \pm 0.0036	0.0014 \pm 0.0005
KPCA – Knn, k = 9					
0.9797 \pm 0.0040	0.0203 \pm 0.0040	0.9798 \pm 0.0042	0.9971 \pm 0.0006	0.9795 \pm 0.0042	0.0029 \pm 0.0006

Anexo 15: Validación en las muestras del movimiento sentado de pie.

Movimiento sentado de pie					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9981 \pm 0.0029	0.0023 \pm 0.0042	0.9977 \pm 0.0040	0.9988 \pm 0.0020	0.9977 \pm 0.0044	0.0012 \pm 0.0020
PCA – Knn, k = 5					
0.9987 \pm 0.0017	0.0013 \pm 0.0017	0.9987 \pm 0.0017	0.9993 \pm 0.0008	0.9986 \pm 0.0018	0.0007 \pm 0.0008
KPCA – Knn, k = 5					
0.9967 \pm 0.0027	0.0033 \pm 0.0027	0.9966 \pm 0.0028	0.9983 \pm 0.0014	0.9967 \pm 0.0027	0.0017 \pm 0.0014
Knn , k = 7					
0.9975 \pm 0.0032	0.0023 \pm 0.0042	0.9978 \pm 0.0039	0.9988 \pm 0.0021	0.9976 \pm 0.0042	0.0012 \pm 0.0021
PCA – Knn, k = 7					
0.9977 \pm 0.0035	0.0023 \pm 0.0035	0.9976 \pm 0.0037	0.9988 \pm 0.0018	0.9977 \pm 0.0035	0.0012 \pm 0.0018
KPCA – Knn, k = 7					
0.9963 \pm 0.0025	0.0037 \pm 0.0025	0.9964 \pm 0.0026	0.9982 \pm 0.0012	0.9962 \pm 0.0025	0.0018 \pm 0.0012
Knn, k = 9					
0.9968 \pm 0.0034	0.0030 \pm 0.0037	0.9970 \pm 0.0038	0.9985 \pm 0.0018	0.9970 \pm 0.0036	0.0015 \pm 0.0018
PCA – Knn, k = 9					
0.9970 \pm 0.0033	0.0030 \pm 0.0033	0.9971 \pm 0.0032	0.9985 \pm 0.0016	0.9969 \pm 0.0035	0.0015 \pm 0.0016
KPCA – Knn, k = 9					
0.9957 \pm 0.0045	0.0043 \pm 0.0045	0.9957 \pm 0.0044	0.9978 \pm 0.0023	0.9957 \pm 0.0043	0.0022 \pm 0.0023

Anexo 16: Validación en las muestras del movimiento alternación en las manos.

Movimiento alternación manos					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9910 \pm 0.0060	0.0075 \pm 0.0049	0.9903 \pm 0.0079	0.9949 \pm 0.0071	0.9951 \pm 0.0070	0.0051 \pm 0.0071
PCA – Knn, k = 5					
0.9930 \pm 0.0071	0.0070 \pm 0.0071	0.9911 \pm 0.0109	0.9947 \pm 0.0105	0.9953 \pm 0.0089	0.0053 \pm 0.0105
KPCA – Knn, k = 5					
0.9740 \pm 0.0084	0.0260 \pm 0.0084	0.9730 \pm 0.0095	0.9755 \pm 0.0120	0.9744 \pm 0.0136	0.0245 \pm 0.0120
Knn , k = 7					
0.9896 \pm 0.0076	0.0115 \pm 0.0094	0.9867 \pm 0.0171	0.9899 \pm 0.0094	0.9901 \pm 0.0095	0.0101 \pm 0.0094
PCA – Knn, k = 7					
0.9920 \pm 0.0082	0.0080 \pm 0.0082	0.9918 \pm 0.0066	0.9926 \pm 0.0130	0.9915 \pm 0.0148	0.0074 \pm 0.0130
KPCA – Knn, k = 7					
0.9665 \pm 0.0189	0.0335 \pm 0.0189	0.9640 \pm 0.0233	0.9696 \pm 0.0207	0.9683 \pm 0.0246	0.0304 \pm 0.0207
Knn, k = 9					
0.9874 \pm 0.0073	0.0105 \pm 0.0069	0.9909 \pm 0.0075	0.9881 \pm 0.0076	0.9879 \pm 0.0082	0.0119 \pm 0.0076
PCA – Knn, k = 9					
0.9870 \pm 0.0079	0.0130 \pm 0.0079	0.9908 \pm 0.0093	0.9836 \pm 0.0155	0.9827 \pm 0.0169	0.0164 \pm 0.0155
KPCA – Knn, k = 9					
0.9640 \pm 0.0145	0.0360 \pm 0.0145	0.9567 \pm 0.0168	0.9714 \pm 0.0207	0.9702 \pm 0.0242	0.0286 \pm 0.0207

Anexo 17: Validación de las muestras en el movimiento agilidad en pie derecho.

Movimiento agilidad pie derecho					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9795 \pm 0.0078	0.0225 \pm 0.0079	0.9720 \pm 0.0104	0.9830 \pm 0.0103	0.9828 \pm 0.0110	0.0170 \pm 0.0103
PCA – Knn, k = 5					
0.9770 \pm 0.0086	0.0230 \pm 0.0086	0.9748 \pm 0.0121	0.9791 \pm 0.0134	0.9789 \pm 0.0138	0.0209 \pm 0.0134
KPCA – Knn, k = 5					
0.9640 \pm 0.0115	0.0360 \pm 0.0115	0.9532 \pm 0.0259	0.9739 \pm 0.0086	0.9735 \pm 0.0082	0.0261 \pm 0.0086
Knn , k = 7					
0.9782 \pm 0.0102	0.0235 \pm 0.0091	0.9737 \pm 0.0156	0.9793 \pm 0.0193	0.9790 \pm 0.0187	0.0207 \pm 0.0193
PCA – Knn, k = 7					
0.9775 \pm 0.0092	0.0225 \pm 0.0092	0.9712 \pm 0.0120	0.9830 \pm 0.0117	0.9827 \pm 0.0115	0.0170 \pm 0.0117
KPCA – Knn, k = 7					
0.9645 \pm 0.0144	0.0355 \pm 0.0144	0.9513 \pm 0.0236	0.9765 \pm 0.0181	0.9768 \pm 0.0151	0.0235 \pm 0.0181
Knn, k = 9					
0.9710 \pm 0.0119	0.0300 \pm 0.0115	0.9603 \pm 0.0187	0.9800 \pm 0.0117	0.9796 \pm 0.0116	0.0200 \pm 0.0117
PCA – Knn, k = 9					
0.9740 \pm 0.0091	0.0260 \pm 0.0091	0.9678 \pm 0.0153	0.9796 \pm 0.0122	0.9801 \pm 0.0111	0.0204 \pm 0.0122
KPCA – Knn, k = 9					
0.9585 \pm 0.0136	0.0415 \pm 0.0136	0.9466 \pm 0.0177	0.9703 \pm 0.0183	0.9691 \pm 0.0193	0.0297 \pm 0.0183

Anexo 18: validación en las muestras del movimiento agilidad en pie izquierdo.

Movimiento agilidad pie izquierdo					
ACC \pm std	E \pm std	TPR \pm std	TNR \pm std	PPV \pm std	FPR \pm std
Knn, k = 5					
0.9795 \pm 0.0078	0.0225 \pm 0.0079	0.9720 \pm 0.0104	0.9830 \pm 0.0103	0.9828 \pm 0.0110	0.0170 \pm 0.0103
PCA – Knn, k = 5					
0.9770 \pm 0.0086	0.0230 \pm 0.0086	0.9748 \pm 0.0121	0.9791 \pm 0.0134	0.9789 \pm 0.0138	0.0209 \pm 0.0134
KPCA – Knn, k = 5					
0.9640 \pm 0.0115	0.0360 \pm 0.0115	0.9532 \pm 0.0259	0.9739 \pm 0.0086	0.9735 \pm 0.0082	0.0261 \pm 0.0086
Knn , k = 7					
0.9782 \pm 0.0102	0.0235 \pm 0.0091	0.9737 \pm 0.0156	0.9793 \pm 0.0193	0.9790 \pm 0.0187	0.0207 \pm 0.0193
PCA – Knn, k = 7					
0.9775 \pm 0.0092	0.0225 \pm 0.0092	0.9712 \pm 0.0120	0.9830 \pm 0.0117	0.9827 \pm 0.0115	0.0170 \pm 0.0117
KPCA – Knn, k = 7					
0.9645 \pm 0.0144	0.0355 \pm 0.0144	0.9513 \pm 0.0236	0.9765 \pm 0.0181	0.9768 \pm 0.0151	0.0235 \pm 0.0181
Knn, k = 9					
0.9710 \pm 0.0119	0.0300 \pm 0.0115	0.9603 \pm 0.0187	0.9800 \pm 0.0117	0.9796 \pm 0.0116	0.0200 \pm 0.0117
PCA – Knn, k = 9					
0.9740 \pm 0.0091	0.0260 \pm 0.0091	0.9678 \pm 0.0153	0.9796 \pm 0.0122	0.9801 \pm 0.0111	0.0204 \pm 0.0122
KPCA – Knn, k = 9					
0.9585 \pm 0.0136	0.0415 \pm 0.0136	0.9466 \pm 0.0177	0.9703 \pm 0.0183	0.9691 \pm 0.0193	0.0297 \pm 0.0183